



Ghost in the Minecraft

2024.01.10

서승배



Ghost in the Minecraft: Generally Capable Agents for Open-World Environments via Large Language Models with Text-based Knowledge and Memory

Xizhou Zhu^{1,2*}, Yuntao Chen^{3*}, Hao Tian^{2*}, Chenxin Tao^{1,2*}, Weijie Su^{2,4*}, Chenyu Yang^{1*}, Gao Huang¹, Bin Li⁴, Lewei Lu², Xiaogang Wang^{2,5}, Yu Qiao⁶, Zhaoxiang Zhang⁷, Jifeng Dai^{1,6}✉

¹Tsinghua University ²SenseTime Research

³Centre for Artificial Intelligence and Robotics, HKISI, CAS

⁴University of Science and Technology of China

⁵The Chinese University of Hong Kong ⁶Shanghai Artificial Intelligence Laboratory

⁷Institute of Automation, Chinese Academy of Science (CASIA)

{zhuxizhou, gaohuang, daijifeng}@tsinghua.edu.cn, cheniyuntao08@gmail.com

tianhao2@senseauto.com, {tcx20, yangcy19}@mails.tsinghua.edu.cn,

jackroos@mail.ustc.edu.cn, binli@ustc.edu.cn, luotto@sensetime.com

xgwang@ee.cuhk.edu.hk, qiaoyu@pjlab.org.cn, zhaoxiang.zhang@ia.ac.cn

Abstract



논문 설명

- 배경
 - Minecraft는 오픈월드 환경에서 ai agent 연구의 좋은 플랫폼이 되어 왔음.
 - 현재까지의 연구들은 기존의 RL 방법론을 중심으로 ObtainDiamond와 같은 특정한 task에 대하여 성능을 향상시키는 방향으로 수행되었음.
- 문제점
 - 특정한 task에만 유효한 방법을 더 넓은 영역의 task에 적용하기 어렵다.
 - 주로 연구가 수행되었던 ObtainDiamond task에서도 성공률 향상에 한계가 있었음.
- 방법론
 - LLM과 text-based knowledge를 기반으로 주어진 문제에 대하여 high-level의 판단을 내리고, 이를 기반으로 Minedojo와 같은 기존의 모델을 이용해 low-level control로 변환하여 행동을 수행하게 함.
 - LLM decomposer, LLM planner, 그리고 LLM interface의 3개의 과정을 거치는 hierarchical한 방식으로 주어진 문제를 좀더 작은 문제들로 분해하여 low-level control로 변환하기 쉽게 만듦.
 - 이러한 분해 과정에서 LLM이 기존의 knowledge와 memory를 이용할 수 있게 하였음.
- 결과
 - 마인크래프트 아이템 트리의 모든 object를 획득하는 데에 성공하였음
 - ObtainDiamond task에서 67.5%의 성공률을 보이면서 기존 방법의 성공률(20%)를 크게 앞섰음.

Method

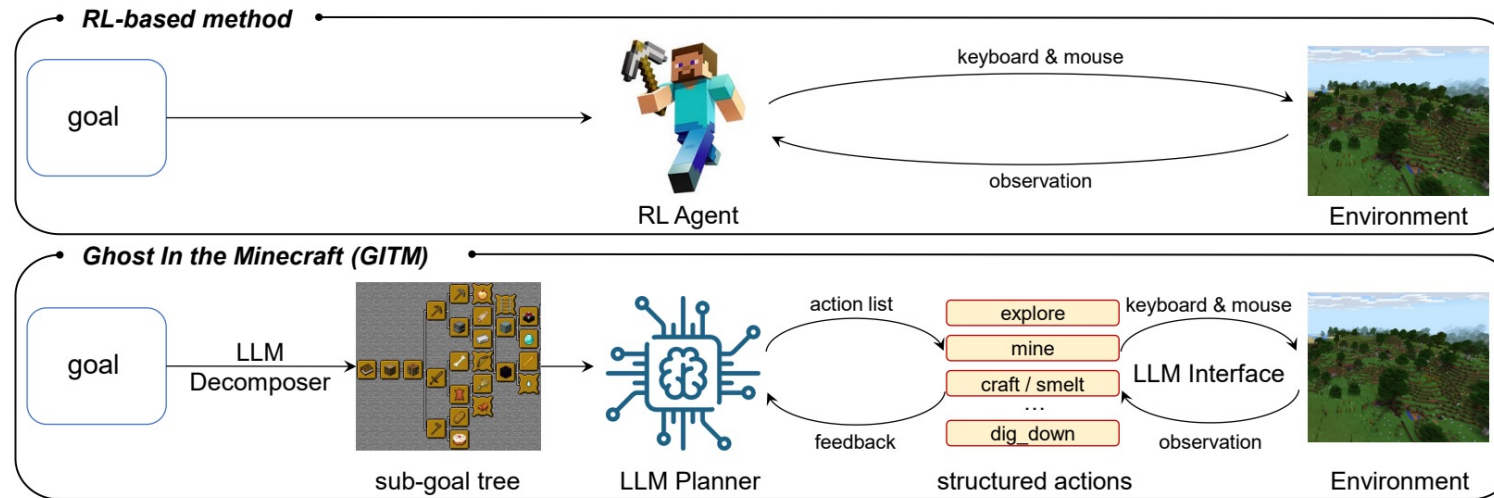


Figure 2: **Comparison between RL-based method and our GITM.** RL agents try to map an complex goal directly to a sequence of low-level control signals, while our GITM leverages LLM to break down the goals and map them to structured actions for final control signals.

Method

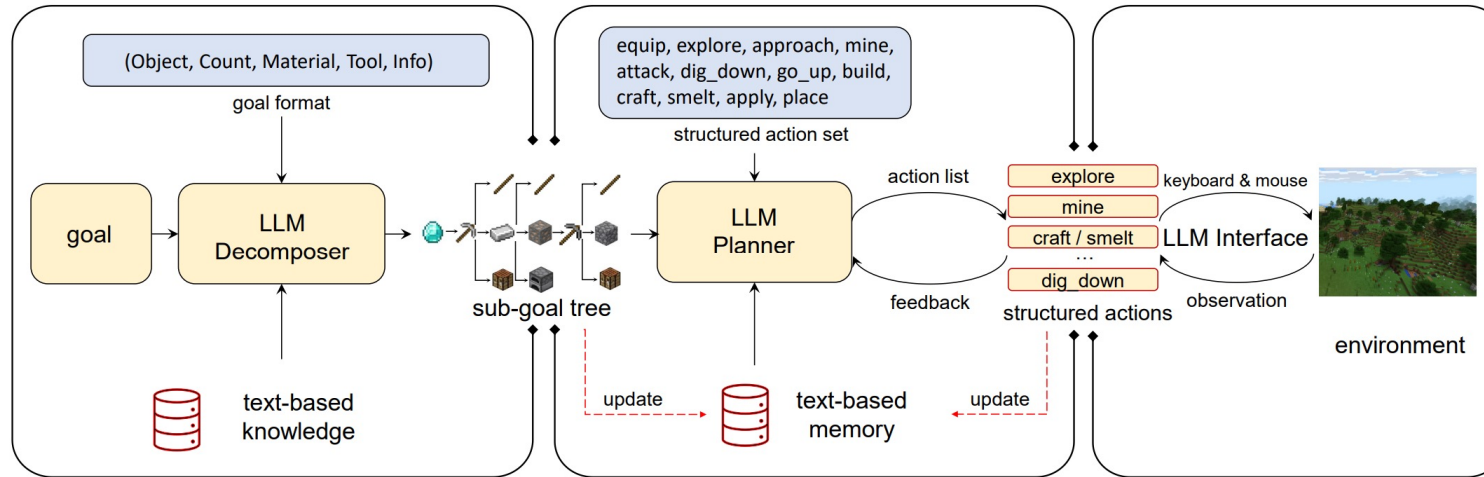


Figure 3: **Overview of our GITM.** Given a Minecraft goal, the LLM Decomposer divides the goal into a sub-goal tree. The LLM Planner then plans an action sequence for each sub-goal. Finally, the LLM Interface executes each action in the environment. Our LLM-based agents can be further enhanced by leveraging text-based knowledge and memory.

- LLM decomposer, LLM planner, 그리고 LLM interface의 3가지 과정으로 구성됨.
- LLM decomposer는 text-based knowledge를 이용하여 주어진 goal을 차례차례 해결할 sub-goal tree로 분해함.
- LLM planner는 하나의 sub-goal이 주어졌을 때 이를 얻을 방법을 정해진 action set에서 조합해서 만듦.
- LLM interface는 이렇게 조합된 action set을 환경에 적용하고, 환경에서 피드백을 받음

Method

LLM decomposer

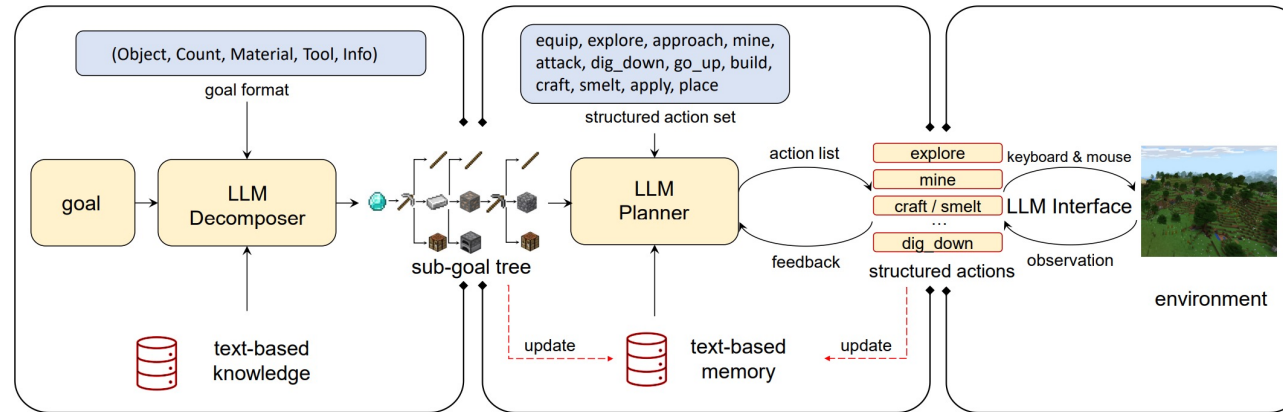
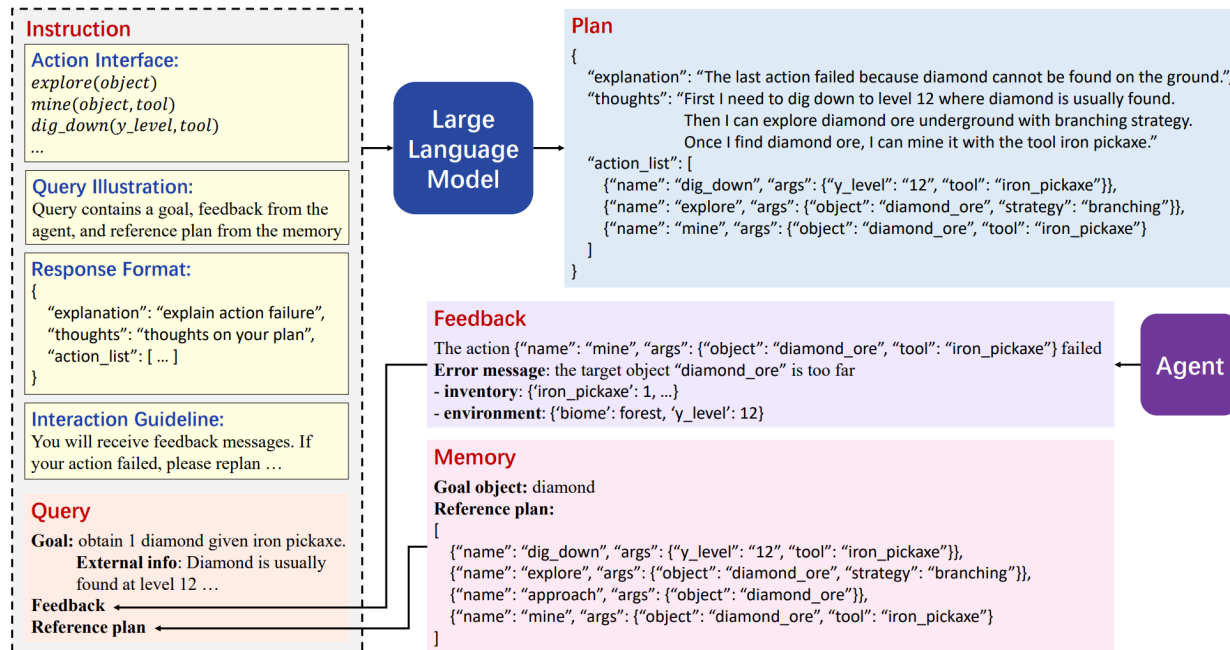


Figure 3: **Overview of our GITM.** Given a Minecraft goal, the LLM Decomposer divides the goal into a sub-goal tree. The LLM Planner then plans an action sequence for each sub-goal. Finally, the LLM Interface executes each action in the environment. Our LLM-based agents can be further enhanced by leveraging text-based knowledge and memory.

- Goal이 주어졌을 때, 이 goal의 sentence embedding을 이용하여 external knowledge base에 접근하여 related knowledge를 가져온다.
- 이러한 goal과 related knowledge를 LLM에 넣어 (object, count, material, tool, info)의 형식으로 결과를 얻는다.
- 여기서 material과 tool은 object를 얻기 위한 prerequisite이며, 이를 새로운 goal로 설정하여 다시 external knowledge를 이용하여 동일한 과정을 반복하여 아이템 트리를 구성할 수 있음
- 이렇게 구성된 sub-goal tree를 차례차례 해결해 나가면 처음 목표에 도달할 수 있음

Method

LLM planner

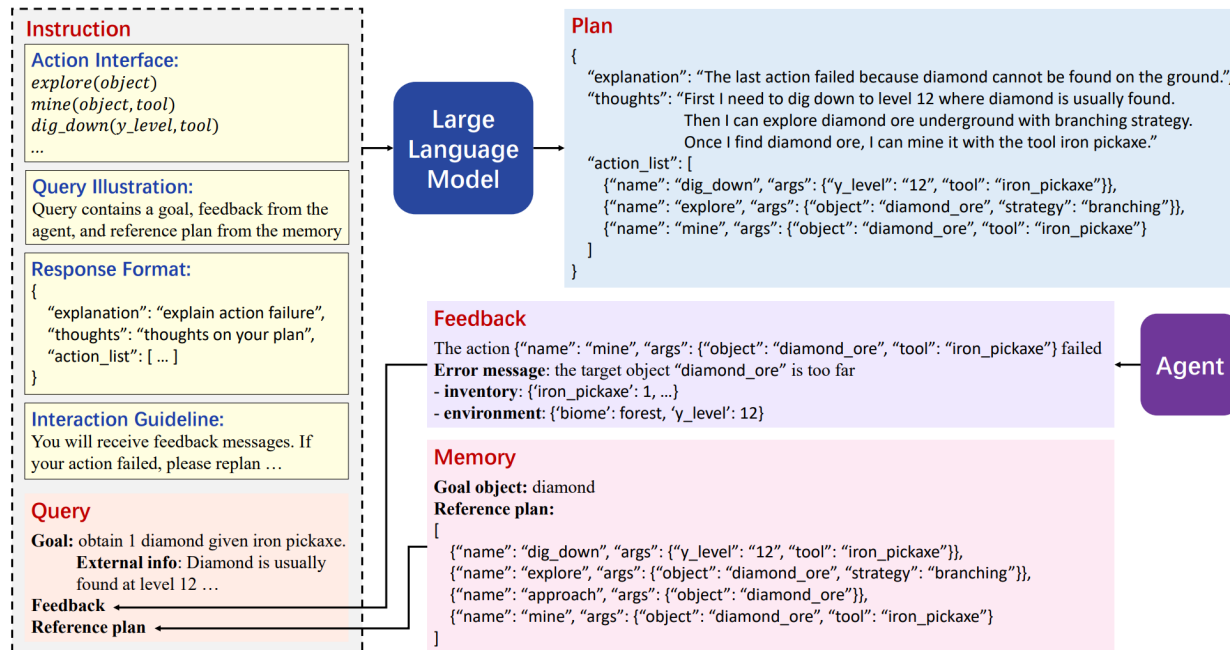


- Sub-goal tree가 완성되면 하나의 목표를 해결할 수 있는 구체적인 지시를 만들어야 함
- LLM이 이를 수행하게 하여, goal이 주어졌을 때 미리 정의된 action set에서 action을 조합하여 이러한 지시를 만들게 한다.
- 지시가 만들어지면 LLM interface에 넘겨서 agent가 지시를 수행하게 하고, 그 결과(성공, 실패)를 feedback로 받아서 만약 실패했을 시 그 원인에 대하여 추론하도록 함으로써 지난 번의 실수를 반복하지 않게 함.

Figure 4: **Illustration of our planning process with the LLM Planner and the agent in the loop.** Given a specific goal, the planner generates plans with structured actions under the guidance of instruction, user query, previous feedback, and reference plan from memory. The agent executes the actions and provides feedback for the following planning.

Method

LLM planner



- 성공 사례들은 memory에 저장되어 다음에 같은 goal이 주어졌을 때 이를 참고할 수 있도록 한다.
- 같은 goal에 대하여 다양한 상황의 variation이 존재할 수 있기 때문에, 성공 사례가 쌓이면 이 중에 핵심적인 action만 남길 수 있도록 또다시 LLM을 이용하여 요약한다.
- 성공 사례가 쌓여서 핵심적인 action들만이 memory에 남게 된다면 다음 번에 같은 goal을 해결해야 할 때 더 효과적으로 참고할 수 있다.


Figure 4: **Illustration of our planning process with the LLM Planner and the agent in the loop.** Given a specific goal, the planner generates plans with structured actions under the guidance of instruction, user query, previous feedback, and reference plan from memory. The agent executes the actions and provides feedback for the following planning.

Method



LLM interface


- 제공된 structured action을 키보드/마우스 움직임으로 변환하고, 환경과의 상호작용으로부터 나타난 결과는 feedback message로 변환한다.
- 기존의 MineDojo model 사용.



Experiments



- “Coverage of the Overworld Technology Tree”와 “Success Rate” 두 개의 평가 방식으로 평가.



- Technology Tree 상의 모든 아이템을 얻는 데에 성공하여 100%의 coverage를 달성함.
- 대부분의 item에 대하여 기존의 방법보다 높은 성공률을 나타냄.






Figure 5: **Success rate for all items in the entire Minecraft Overworld Technology Tree.** The x axis lists all item names. We overlay the results from our GITM and the best results from baselines.

Experiments



- “Coverage of the Overworld Technology Tree”와 “Success Rate” 두 개의 평가 방식으로 평가.






Table 2: Comparison of our GITM with previous methods on ObtainDiamond challenge.






Method	Success Rate (%)				
					
DreamerV3	-	50.0	3.0	0.01	0.01
DEPS	90.0	80.0	73.3	10.0	0.6
VPT	100.0	100.0	100.0	85.0	20.0
Our GITM	100.0	100.0	100.0	95.0	67.5

- Technology Tree 상의 모든 아이템을 얻는데에 성공하여 100%의 coverage를 달성함.
- 대부분의 item에 대하여 기존의 방법보다 높은 성공률을 나타냄.
- 기존에 주로 연구된 ObtainDiamond task에 대하여 더 높은 성공률을 달성함.

Experiments

Ablation study

Table 3: **Ablation study.** The milestone items from left to right are crafting table , wooden pickaxe , stone pickaxe , iron pickaxe , and diamond . The success rate is calculated under time limit of 12000 steps (total) and query limit of 30 (each sub-goal). “Goal Decomp.” and “External Info.” indicates goal decomposition and external knowledge respectively.

Goal Decomp.	Feedback	External Info.	Memory	Success Rate (%)				
								
				57.5	32.5	5.0	0.0	0.0
✓				90.0	90.0	67.5	2.5	0.0
✓	✓			97.5	95.0	77.5	20.0	5.0
✓	✓	✓		100.0	100.0	100.0	57.5	35.0
✓	✓	✓	✓	100.0	100.0	100.0	95.0	67.5

- Goal decomposition, feedback, external information, memory 모두 효과가 있음을 발견하였음.
- 모두 적용하였을 때 ObtainDiamond task에 대하여 67.5%의 성공률을 보임.

Conclusion



- LLM과 external knowledge를 이용하여 복잡한 목표 지향적 문제를 해결할 수 있다.
- 기존 RL 방법에서 어려운 점이었던 long-horizon, complex task를 위한 agent를 개발하는 것에 있어 LLM의 가능성을 보여주었다.
- 마인크래프트가 아닌 다른 문제에 적용한다면?



H C C
L A B
S N U

QnA