

ФОРМУВАННЯ FEW-SHOT ПРИКЛАДІВ НА ОСНОВІ ІСТОРІЇ ДІЙ АГЕНТА

Махотіло В.К.

e-mail: volodymyr.makhotilo@nure.ua

Науковий керівник – к.т.н., проф. Шевченко О.Ю.

Харківський національний університет радіоелектроніки, каф. ШІ
м. Харків, Україна

This work proposes an approach to improving LLM-based agents in long-horizon planning tasks through dynamic context adaptation and experience-driven few-shot learning. Built on the Reason–Act–Observe–Reflect framework with hierarchical task decomposition, the method addresses the inability to provide effective few-shot demonstrations in advance due to dynamic interaction states. The agent accumulates interaction trajectories during execution and converts them into adaptive few-shot examples. This reduces hallucinations and improves performance on complex multi-step tasks.

З кожним роком кількість програмних систем, побудованих на основі LLM-агентів, стрімко зростає [1]. Зі збільшенням складності задач, що розв'язуються за допомогою LLM-агентів, у науковій літературі було виокремлено клас задач довгогоризонтного планування [2]. Ці задачі характеризуються необхідністю виконання великої кількості послідовних дій для досягнення кінцевої мети, при цьому початкове завдання часто задається у вигляді високорівневого опису без детального плану його реалізації. У таких умовах агенти можуть демонструвати низку характерних проблем, зокрема помилкову інтерпретацію стану середовища, виникнення галюцинацій та вибір неефективних дій, що призводить до потрапляння у неоптимальні або тупикові траєкторії виконання задачі.

Одним із підходів до розв'язання задач довгогоризонтного планування є розширення класичної моделі взаємодії агента із середовищем типу Reason–Act–Observe, запропонованої у підході ReAct [3]. У подальших дослідженнях цей цикл було доповнено етапом Reflect [4], який дозволяє агенту аналізувати результати попередніх дій, узагальнювати отриманий досвід та коригувати подальшу стратегію прийняття рішень. Високу ефективність також продемонстрували методи ієрархічного планування [5], які передбачають декомпозицію складної задачі на підзадачі різних рівнів абстракції та дозволяють поєднувати переваги глобального планування, що формує загальну стратегію досягнення мети, і локального планування, спрямованого на вибір конкретних дій у поточному стані середовища.

Важливим елементом мультиагентних систем є few-shot prompting – техніка, що передбачає надання моделі прикладів виконання задачі. У традиційному підході такі приклади задаються статично, однак для задач

довгогоризонтного планування це часто є неефективним, оскільки структура задачі може змінюватися у процесі її виконання.

Запропонований метод передбачає динамічне регулювання політики прийняття рішень шляхом адаптивного формування контексту на основі накопиченого досвіду.

На початковому етапі вихідна задача піддається ієрархічній декомпозиції, у результаті чого формується послідовність глобальних та локальних підзадач. Для кожної локальної підзадачі формується контекст запиту до мовної моделі, до якого за наявності додаються релевантні few-shot демонстраційні приклади, сформовані на основі попереднього досвіду агента.

Розв'язання кожної підзадачі здійснюється в межах ітеративного циклу Reason–Act–Observe–Reflect. У цьому циклі агент аналізує поточний стан середовища, генерує дію, виконує її та отримує спостереження щодо результату. На основі отриманого зворотного зв'язку виконується етап рефлексії, що дозволяє коригувати подальші дії. Процес повторюється до моменту завершення підзадачі або досягнення встановленого обмеження на кількість ітерацій.

Після завершення або невдалого виконання локальної підзадачі накопичена історія взаємодії агента із середовищем перетворюється на структуроване знання та зберігається у пам'яті системи. Надалі ці знання використовуються для формування нових few-shot демонстрацій, які можуть включатися до контексту запиту під час розв'язання наступних підзадач. Це сприяє поступовому покращенню політики прийняття рішень агента.

Результуючий метод має на меті зменшення кількості галюцинацій мовної моделі та підвищення ефективності розв'язання складних багатокрокових задач шляхом збагачення контексту запиту, використовуючи акумульовані знання.

Список використаних джерел:

1. Gryshko S., Terziyan V., Golovianko M. Resilience training in higher education: AI-assisted collaborative learning. Lecture notes in networks and systems. Cham, 2025. P. 126–138. DOI: https://doi.org/10.1007/978-3-031-83520-9_12.
2. Erdogan L. E., Lee N. Plan-and-Act: improving planning of agents for long-horizon tasks. arxiv:2503.09572, 2025.
3. Mu X., Zhuo H. H., Hierarchical task network planning for facilitating cooperative multi-agent reinforcement learning. arxiv:2306.08359, 2023.
4. Shinn N., Cassano F. Reflexion: language agents with verbal reinforcement learning. arxiv:2303.11366, 2023.
5. Yao S., Zhao J. ReAct: synergizing reasoning and acting in language models. arxiv:2210.03629, 2022.