

## **N-EXТ AGENT SLMs: ОБУЧЕНИЕ МАЛЫХ ДИАЛОГОВЫХ ЯЗЫКОВЫХ МОДЕЛЕЙ ДЛЯ РАСПОЗНАВАНИЯ НЕЯВНЫХ ЗАПРОСОВ**

*Калиниченко Владислав Владимирович<sup>1</sup>  
Багаутдинова Алина Раисовна<sup>2</sup>*

1: *Студент, факультет Информатики и Вычислительной техники,  
Иннополис, Россия*

2: *Студентка, Северо-Кавказский Федеральный Университет, Ставрополь,  
Россия*

3: *Научный руководитель — Лапина Мария Анатольевна  
E-mail: pinkod200586@gmail.com, bagaauttdinova@mail.ru*

В современных диалоговых системах возникает проблема недостаточной способности языковых моделей распознавать неявные запросы. Настоящее исследование нацелено на разработку эффективных Агентных Малых Языковых Моделей, распознающих нечётко выраженные запросы (**Non-explicit Trigger Agent SLMs**), способные предугадывать потребности пользователя, даже если они не выражены явно. В работе представляется концепция неявных запросов, создаётся синтетический датасет и обучается Малая Языковая Модель.

Неявные запросы — это потребности или желания пользователя, которые не выражены прямым образом, но могут быть выведены из контекста и невербальных признаков общения. Например, контекстуальный запрос: «У меня день рождения через неделю» (Неявный запрос: Предложи идеи для празднования); невербальный запрос: Пауза в монологе (Неявный запрос: Предложи продолжение мысли); Запрос на сохранение в память модели: «Я обычно ложусь спать в девять» (Неявный запрос: Присылай уведомления в 8).

Основная задача — обучение малых языковых моделей, ограниченных примерно одним миллиардом параметров, для локальной работы на мобильных устройствах, с помощью синтетического датасета, для повышения удобства использования в повседневной жизни.

В качестве базовой модели использовалась TinyLlama 1.1B, для эффективной работы на мобильных устройствах. Производилось обучение модели с помощью библиотеки Hugging Face Transformers вызывать различные API, даже если пользователь неявно указал на необходимость действий или использования определённых сервисов.

Были разработаны три типа неявных запросов:

1. Прекращение прослушивания голосового ввода и вмешательство после некоторого периода молчания.
2. Запоминание информации в векторную базу данных при рассказе пользователем о привычках, потребностях или императивном призыве к некоторому поведению модели.
3. Вызов соответствующих API умного дома или приложений, когда пользователь указывает на конкретные ситуации.

Был создан датасет в JSON формате с более чем 300 примерами взаимодействий пользователя и модели, аугментированными вызовами API в формате `<API> Действие </API>`.

После завершения fine-tune стадии TinyLlama 1.1B были достигнуты значительные успехи в обучении модели обрабатывать неявные запросы. Модель успешно освоила механизм вызова различных API, даже если пользователь прямо не указывал на необходимость их использования. Это позволило модели более гибко реагировать на контекст и предоставлять более релевантные и интуитивные ответы на неочевидные сигналы от пользователя.

Развитие N-exT Agent SLM представляет собой перспективное направление для дальнейших исследований в области обучения малых языковых моделей с фокусом на неявных запросах, обеспечивая более эффективное взаимодействие с пользователем в ограниченных вычислительных средах.

### Литература

1. Schick T. Toolformer: Language Models Can Teach Themselves to Use Tools // ArXiv 2023
2. Eldan R. TinyStories: How Small Can Language Models Be and Still Speak Coherent English? // ArXiv 2023
3. Qin Y. ToolLLM: Facilitating Large Language Models To Master 16000+ Real-World APIs // ArXiv 2023