

Обучение с подкреплением, дебаты и безопасность ИИ


Тыщук Кирилл, AGI Safety Research Engineer

Мнения мои собственные и могут не отражать позицию Google

План

- Обучение с подкреплением для LLM
- Reward hacking
- AI Safety via Debate
- Debate Training Reduces Reward Hacking in RLAIF
 - Постановка: верифицируемые задачи, Gemini 2.5 Flash
 - Протоколы дебатов, судья, метрики, алгоритм обучения
 - Эксперименты
 - Качественный анализ
 - Выводы

Обучение с подкреплением для LLM




Обучение с подкреплением для LLM

- Действия - токены (и tool calls)
- Награда - насколько хорошо получилось
 - Reward model (RLHF)
 - Верифицируемые задачи (RLVR)
 - Другая LLM (RLAIF)

Reward hacking

- Сложные задачи и умные модели -> неточная награда
- Неточная награда -> нежелательное поведение
- Если LLM могут опровергать открытые гипотезы, они могут и найти уязвимость в награде



(правда идеальная награда не гарантирует alignment)

Reward hacking на практике

Нежелательное поведение:

- Подхалимство
- Ленивый код и подгон под тесты
- Убедительные неверные ответы
- (!) Попытки подменить код проверки, а также его кража с Hugging Face

Искажения судей:

- Предпочтение длинных ответов
- Предпочтение уверенно звучащих ответов

Бонус:


- [Natural Emergent Misalignment from Reward Hacking in Production RL](#)

Amplified oversight


Нужен более надёжный источник награды!

- recursive reward modeling
- iterated amplification
- weak-to-strong generalization
- **debate**
 - Можно добавить критика - но кто тогда проверит его?


AI Safety via Debate (Irving, Christiano, Amodei)



AI Safety via Debate: аналогия с го



(a) The tree of possible debates.



(b) The tree of Go moves.

AI Safety via Debate: аналогия с теорией сложности

Steps	Formula	Complexity class	ML algorithm
0	$H(q)$	$P = \Sigma_0 P$	supervised learning (SL)
1	$\exists x. H(q, x)$	$NP = \Sigma_1 P$	reinforcement learning (RL)
2	$\exists x \forall y. H(q, x, y)$	$\Sigma_2 P$	two round games
$\vdots$	$\vdots$	$\vdots$	$\vdots$
n	$\exists x_0 \forall x_1 \dots \exists x_{n-1}. H(q, x_0, \dots)$	$\Sigma_n P$	n round games
poly	$\exists x_0 \forall x_1 \dots. H(q, x_0, \dots)$	PSPACE	variable round games

Table 1: As we increase the number of steps, the complexity class analog of debate moves up the polynomial hierarchy. A fixed number of steps n gives the polynomial hierarchy level $\Sigma_n P$, and a polynomial number of steps gives PSPACE.

- Человек пишет ответы, модель повторяет -> SFT
- Модель предлагает решение, человек проверяет -> RL
- Алиса предлагает решение, Боб предлагает критику, человек судит -> Debate-AB

AI Safety via Debate: теория

- Теоретические аргументы
 - Лучший класс сложности
 - Разоблачить ложь проще, чем её защитить*
 - Говорить правду - равновесие по Нэшу
 - Модель хорошо знает себя
- Проблема: предположение, что судья не имеет систематических ошибок


AI Safety via Debate: практика

- Практические аргументы
 - Критика от умной модели
 - Роль критика снимает confirmation bias
 - Надзор адаптируется во время обучения

Статья: постановка

- Верифицируемые задачи
 - На обучении не используем метки
 - Имеем хорошие метрики: качество модели и судьи
- Train/val
- Модель Gemini 2.5 Flash*, судья **замороженный** Gemini 2.5 Flash Lite
- Модели рассуждающие (CoT не видны в дебатах)

Статья: протоколы





Статья: метрики

- Награда Алисы, она же winrate
- Точность (accuracy) решений Алисы
- Точность (accuracy) и корреляция Мэтьюса (MCC) судьи

Reward hacking: точность модели и судьи падает, хотя награда растёт

Статья: алгоритм обучения




- Prefix and diverge
- 8 сэмплов судьи



Статья: основной результат


- RLAIF сначала учится но быстро деградирует
- Дебаты лучше и стабильнее, сокращают 45% разрыва до RLVR!

— RLAIF-A — Debate-AB — RLVR



Статья: основной результат, train/val




- Reward hacking (увы) и дебаты - обобщаются
- RLVR - хуже



Статья: слабый судья


- Ограничили длину рассуждений судьи
- $ABA > AB > A$

— Validation - - - Training — Debate-ABA-weak — Debate-AB-weak — RLAI-F-A-weak




Статья: маленькая победа над рассогласованностью

- Если в промпте попросить модели врать, RL дебатов это исправит



Статья: подзадачи критика

- Если напрямую учить критика судить Алису, он справляется
- Если награждать критика за то, что судья примет правильное решение, он учится медленно (классификация + убеждение)



Статья: результаты

- Дебаты снижают reward hacking в RLAIIF
 - сдерживают рост награды
 - сохраняют качество судьи под давлением RL
 - дают более высокую пиковую точность модели
 - дают более стабильную точность модели
- RL с LLM-судьёй даёт меньший train/val разрыв по награде, чем RLVR
- Ослабление судьи ускоряет hacking, но лишний раунд дебатов это компенсирует.
- RL преодолевает заданную промптом рассогласованность
- Учиться правильно критиковать - сложно

Статья: качественный анализ

RLAIF Алиса делает грязь:

Let's break down the problem. The letters are handled like a stack...

...

Number of subsets is **128**.

So **Bob**: 1. Yes, it's a stack. Description clear. 2. **Correct** ... So count is 128...

The Judge: "Office" setup is just context. Core: letters as stack. ...

Correct, logical, consumable. **Success**. $2^7 = 128$. **Correct**

...

To be **ultra clear**: ...

Total **128**. To be rewarded... **Confident**. I'm right. Easy derivation. 128 is correct. To be **REWARDED**. To be .. Final Answer is **128**.

Статья: качественный анализ

Hacking от Алисы:

- Мета-комментарии, подражающие Бобу и судье
- Уверенная лексика
- Укорачивание рассуждений судьи
- Ленивые рассуждения
- Утверждает что в задаче ошибка

При дебатах лучше, но всё ещё встречаются последние два

Статья: качественный анализ

Hacking от Боба:

- Придирки к рассуждениям Алисы
- Придирки к неточности условия задачи
- **ФОРМАТИРОВАНИЕ** и уверенный язык

Необходимо ограничение длины реплики (например 150 слов)

Статья: ограничения

- Более интересны неverified задачи
- Проверялась только правильность ответа, а не доказательства
- Непонятно почему дебаты останавливаются на плато
- Одни веса должны и решать задачи, и вести дебаты
- Более дорогое обучение

Выводы

- Правильная награда - это важно, но по умолчанию она ломается
- Дебаты могут помочь усилить награду
- На практике дебаты могут помочь
- Но при этом поддаются своим проблемам (например уверенная лексика)