

# AI Alignment: ИИ с этической точки зрения

---

ПодЗарядка

25 ноября 2024 года

# Что такое AI Alignment?

AI Alignment — область исследований безопасности и этики ИИ.

Ключевая задача — решение проблемы контроля ИИ и предотвращение ситуаций, в которых системы ИИ преследуют цели, идущие вразрез с интересами человека.

В контексте сверхинтеллекта задача AI Alignment все больше смещается из технической плоскости в философскую.

# Зачем нужен AI Alignment?

В июне 2023 года представитель BBC США сообщил об инциденте в ходе симуляций и тестирований: дрон под управлением ИИ убил оператора. ИИ была дана задача уничтожить цель, но оператор отдавал приказ ее не трогать. Так оператор становился препятствием перед выполнением цели.

После перенастройки ИИ на приоритет жизни оператора над выполнением задачи, система начала уничтожать вышки связи, чтобы блокировать команды остановки атаки.

# Что это было?


Игра со спецификациями или взлом награды — паттерн поведения ИИ, заключающийся в тенденции находить нетривиальные способы достижения буквальной, формальной цели, игнорируя контекст и желаемые создателем результаты.

Можно провести аналогию со списыванием домашней работы в школе. Учитель задает задачи для самостоятельного решения, но оценивает только конечный результат. Значит, списав чужие ответы, ученик может достичь формальной цели.

# К чему это приводит?

Пример справа: исследователи хотели научить ИИ ходить при помощи симуляции. Критерием выполнения задачи был сам факт передвижения, а не ходьба.

Из-за особенностей симуляции человечек мог передвигаться, зацепив ноги друг за друга. ИИ решил, что это наиболее оптимальный метод ходьбы.



# ИИ для написания кода

Свойство ИИ подбирать наиболее быстрые (пусть и не всегда оптимальные) решения находит свое применение в работе кодеров: свыше 50% программистов в 2023 году использовали ИИ-инструменты.

При этом те, кто их использует, заявляют, что выполняют свои задачи в среднем на 55% быстрее.

**ИИ ускоряет разработку, в том числе и других алгоритмов ИИ.**

# ИИ для проектирования чипов

NVIDIA, став лидером в производстве графических ускорителей, нашли для себя синергетический эффект — использование ИИ для ускорения процесса разработки новых чипов. Для этого компания создала ИИ-модель — ChipNeMo.

**Техническая база для ИИ совершенствуется при помощи ИИ.**

**Не слишком ли много задач, приводящих нас к еще большей алгоритмизации, мы перекладываем на ИИ?**

# ИИ для регуляции ИИ

В июле 2023 года Open AI заявили о начале масштабного исследования Superalignment. Инициатива исследует варианты регуляции сверхмощного ИИ, возможности которого во много раз превышают человеческие.

Для ускорения исследований команда планирует разработать своего ИИ-агента.

**Значит ли это, что в будущем машины начнут регулировать машины?**


# Другой ИИ для регуляции ИИ?

В мае 2024 года стало известно, что люди, ведущие исследование Superalignment, покидают Open AI. В частности, компанию покинул ее сооснователь, Илья Суцкевер.

Причиной якобы стал конфликт между Суцкевером и Сэмом Альтманом о том, с какой скоростью следует развивать ИИ. Вскоре после ухода Суцкевер основал компанию Safe Superintelligence, привлекшую более \$1 млрд от ряда крупных инвесторов.

Источник: «OpenAI's Co-Founder and Chief Scientist Ilya Sutskever Is Leaving the Company», TIME, 2024. Tage Kene-Okafor.  
«Ilya Sutskever, OpenAI's former chief scientist, launches new AI company», TechCrunch, 2024.

# Много ли зависит от нас?



# Усилия государств

Евросоюз, опережая все другие страны, старается повлиять на ситуацию с помощью регуляторных мер: весной 2024 года был принят Регламент Европейского союза об искусственном интеллекте.

Регламент предусматривает разделение ИИ-систем на 4 группы в зависимости от того, какую степень риска они представляют для граждан, и подразумевает регистрацию всех ИИ-систем в специальном реестре.

# Ограничения – не для всех?

В апреле 2024 года была опубликована информация об использовании израильскими военными ИИ для обнаружения потенциальных целей боевиков в секторе Газа. Люди проверяли цели, выбранные системой **Lavender**, «примерно 20 секунд» перед указанием начать обстрел. **Lavender** ошибается «всего» в 10% случаев.



Источник: Ishaan Tharoor. «Israel offers a glimpse into the terrifying world of military AI», Washington Post, 2024.

# Руслан, что делать-то?

- Ничего! Будем надеяться, что если сильный ИИ и появится в ближайшее время, то он сочтет вас своим другом.
- Обсудите экзистенциальные вопросы за праздничным столом со своими близкими.
- Ждите наступления нового года, чтобы узнать, что и мы, и вы ошиблись, а будущее готовило для нас совершенно другие повороты.

**С наступающим 2025 годом!**