



# Хроники AGI

Антон Конушин

К.ф.-м.н.

В.н.с., рук.группы «Пространственный интеллект» AIRI


В.н.с., научный руководитель Центра ИИ МГУ имени М.В. Ломоносова

Зам.декана по научной работе Факультета ИИ МГУ имени М.В. Ломоносова


Программный директор Фонда «Интеллект»

# Развитие и распространение технологий - экспонента

Жизнь полна экспоненциальных процессов («сложных процентов»), а мозг работает как машина линейного предсказания



Закон Мура – рост скорости  
вычислений CPU




Прогноз на будущее?

[Д.Ватолин CAGR как проклятие специалистов, или ошибки прогнозирования экспоненциальных процессов](#)


# Экспонента поддерживается инновациями



# Проникновение технологий в современном мире



# Эвристика нам в помощь



# Революция генеративного ИИ (2022 год)




**You**

Please, write a short poem (4 lines) about Anton, who hurries to make slides in time for his talk on AI revolution




**ChatGPT**

In haste, Anton crafts slides with keen devotion,  
An AI revolution, his speech in motion.  
Bytes of knowledge, a symphony in slides,  
In the spotlight, he unveils where progress resides.



# Аutoregressive model



GPT = Generative Pre-Trained Transformer

# Получение знаний из текстов через генеративное обучение

**Ruth Marianna Handler** (*née Mosko*; November 4, 1916 – April 27, 2002) was an American businesswoman and inventor. She is best known for inventing the Barbie doll in 1959,<sup>[2]</sup> and being co-founder of toy manufacturer Mattel with her husband Elliot, as well as serving as the company's first president from 1945 to 1975.<sup>[3]</sup>

The Handlers were forced to resign from Mattel in 1975 after the Securities and Exchange Commission investigated the company for falsifying financial documents.<sup>[3][4]</sup>

## Early life <sup>[edit]</sup>

Ruth Marianna Mosko<sup>[5][2][3]</sup> was born on November 4, 1916, in Denver, Colorado, to Polish-Jewish immigrants Jacob Moskowitz, a blacksmith, and Ida Moskowitz, née Rubenstein.<sup>[6]</sup>

She married her high school boyfriend, Elliot Handler, and moved to Los Angeles in 1938, where she found work at Paramount.<sup>[7]</sup>

**Ruth Handler**



Handler in 1961

|             |                                                                                  |
|-------------|----------------------------------------------------------------------------------|
| <b>Born</b> | Ruth Marianna Mosko<br>November 4, 1916<br><u>Denver, Colorado</u> , U.S.        |
| <b>Died</b> | April 27, 2002 (aged 85) <sup>[1]</sup><br><u>Los Angeles, California</u> , U.S. |

# Масштабирование моделей

|                      | <u>GPT-1</u><br>(2018) | <u>GPT-2</u><br>(2019) | <u>GPT-3</u><br>(2020)  |
|----------------------|------------------------|------------------------|-------------------------|
| Number of parameters | 117 million            | 1.5 billion            | 175 billion             |
| Training data        | 5 GB                   | 40 GB                  | 45 TB (i.e., 45 000 GB) |


Large Language Model (LLM) = Большая Языковая Модель (БЯМ)

Alec Radford et. al. [Improving Language Understanding by Generative Pre-Training](#). 2018 (GPT-1)


Alec Radford et.al. [Language Models are Unsupervised Multitask Learners](#). 2019 (GPT-2)

Tom Brown et. al. [Language Models are Few-Shot Learners](#). 2020 (GPT-3)

# Эмерджентные (emergent) свойства при масштабировании



# БЯМ как сжатая версия всех текстов человечества



Chunk of the internet,  
~10TB of text



6,000 GPUs for 12 days, ~\$2M  
~1e24 FLOPS



parameters.zip

~140GB file

# БЯМ как фундаментальная модель

Фундаментальная модель = способна решать новые задачи без нового обучения / дообучения

|                | zero-shot                                | few-shot                                         |                                                  |
|----------------|------------------------------------------|--------------------------------------------------|--------------------------------------------------|
|                |                                          | one-shot                                         | two-shot                                         |
| Input (prompt) | Review: I love this movie!<br>Sentiment: | Review: This movie sucks.<br>Sentiment: negative | Review: This movie sucks.<br>Sentiment: negative |
|                |                                          | Review: I love this movie!<br>Sentiment:         | Review: This was cool!<br>Sentiment: positive    |
|                |                                          |                                                  | Review: I love this movie!<br>Sentiment:         |
| Model output   | positive                                 | positive                                         | positive                                         |


Мы решаем новые задачи с помощью БЯМ, описывая ей задачу текстом и давая примеры работы

# Превращаем БЯМ в чат-бот (ассистента)


Step 1

**Collect demonstration data,  
and train a supervised policy.**


A prompt is  
sampled from our  
prompt dataset.



A labeler  
demonstrates the  
desired output  
behavior.



This data is used  
to fine-tune GPT-3  
with supervised  
learning.



**<USER>**

Can you write a short introduction about the relevance of the term "monopsony" in economics? Please use examples related to potential monopsonies in the labour market and cite relevant research.

**<ASSISTANT>**

"Monopsony" refers to a market structure where there is only one buyer for a particular good or service. In economics, this term is particularly relevant in the labor market, where a monopsony employer has significant power over the wages and working conditions of their employees. The presence of a monopsony can result in lower wages and reduced employment opportunities for workers, as the employer has little incentive to increase wages or provide better working conditions...

Дообучаем модель на множестве примеров решения разных задач,  
которые подготовили эксперты

**~100K conversations**

# Обучение с подкреплением

Step 1

**Collect demonstration data,  
and train a supervised policy.**


A prompt is  
sampled from our  
prompt dataset.

Explain the moon  
landing to a 6 year old

A labeler  
demonstrates the  
desired output  
behavior.

Some people went  
to the moon...

This data is used  
to fine-tune GPT-3  
with supervised  
learning.



Step 2

**Collect comparison data,  
and train a reward model.**

A prompt and  
several model  
outputs are  
sampled.


Explain the moon  
landing to a 6 year old

A Explain gravity...  
B Explain war...  
C Moon is natural  
satellite of...  
D People went to  
the moon...

A labeler ranks  
the outputs from  
best to worst.

D > C > A = B

This data is used  
to train our  
reward model.




Step 3

**Optimize a policy against  
the reward model using  
reinforcement learning.**

- Обучение с подкреплением (Reinforcement Learning, RL) = подход к обучению, когда у нас нет «правильного» ответа, но есть способ оценить качество ответа или сравнить ответы друг с другом
- Благодаря RL мы можем учиться решать задачи, для которых у нас нет готовых данных или их слишком мало

# Обучение с подкреплением и оригинальность



Модель AlphaGo училась играть сама с собой, и во время матча с Ли Седоком сделала оригинальный ход («Ход №37»), который не сделал бы человек

# Рассуждающие модели

*If a train is moving at 60 mph and travels for 3 hours, how far does it go?*

The train travels 180 miles.

**Plain response**

To determine the distance traveled, use the formula:

Distance = Speed  $\times$  Time

Given that the speed is 60 mph and the time is 3 hours:


Distance = 60 mph  $\times$  3 hours = 180 miles

So, the train travels 180 miles.

**Response with intermediate reasoning steps**

Рассуждения = «думать дольше», обосновывая каждый шаг получения решения

# Обучение рассуждениям через обучение с подкреплением



Цикл работ DeepSeek-V3 и DeepSeek-R1 был «Sputnik moment» для мира в области ИИ

Все ИИ-лаборатории разбирали эти работы

2 основных момента:

- Стратегии обучения рассуждениям
- Умные реализации многих механизмов, включая обучение с пониженной битностью, которые резко повысили эффективность обучения

Стратегии

- Чистый RL
- SFT на цепочках рассуждений
- Дистилляция моделей на цепочках рассуждений

## «Aha-moment»

---

Question: If  $a > 1$ , then the sum of the real solutions of  $\sqrt{a - \sqrt{a + x}} = x$  is equal to

---

Response: <think>

To solve the equation  $\sqrt{a - \sqrt{a + x}} = x$ , let's start by squaring both ...

$$\left(\sqrt{a - \sqrt{a + x}}\right)^2 = x^2 \implies a - \sqrt{a + x} = x^2.$$

Rearrange to isolate the inner square root term:

$$(a - x^2)^2 = a + x \implies a^2 - 2ax^2 + (x^2)^2 = a + x \implies x^4 - 2ax^2 - x + (a^2 - a) = 0$$

...

**Wait, wait. Wait. That's an aha moment I can flag here.**

Let's reevaluate this step-by-step to identify if the correct sum can be ...

We started with the equation:

$$\sqrt{a - \sqrt{a + x}} = x$$

First, let's square both sides:

$$a - \sqrt{a + x} = x^2 \implies \sqrt{a + x} = a - x^2$$

Next, I could square both sides again, treating the equation: ...

...


---

Table 3 | An interesting “aha moment” of an intermediate version of DeepSeek-R1-Zero. The model learns to rethink using an anthropomorphic tone. This is also an aha moment for us, allowing us to witness the power and beauty of reinforcement learning.

## Переход к мультимодальным моделям



# Мультимодальные модели




Извлекаем знания из любых данных и устанавливаем взаимосвязи между ними

# Изображения + текст = учебники

| Art & Design                                                                                                                                                                                                                                                                                                                                                                       | Business                                                                                                                                                                                                                                                                                 | Science                                                                                                                                                                                                                                                                                                                                                                                                            |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p><b>Question:</b> Among the following harmonic intervals, which one is constructed incorrectly?</p> <p><b>Options:</b></p> <p>(A) Major third <i>&lt;image 1&gt;</i></p> <p>(B) Diminished fifth <i>&lt;image 2&gt;</i></p> <p><b>(C) Minor seventh <i>&lt;image 3&gt;</i></b></p> <p>(D) Diminished sixth <i>&lt;image 4&gt;</i></p>                                            | <p><b>Question:</b> ...The graph shown is compiled from data collected by Gallup <i>&lt;image 1&gt;</i>. Find the probability that the selected Emotional Health Index Score is between 80.5 and 82?</p> <p><b>Options:</b></p> <p>(A) 0 (B) 0.2142</p> <p><b>(C) 0.3571</b> (D) 0.5</p> | <p><b>Question:</b> <i>&lt;image 1&gt;</i> The region bounded by the graph as shown above. Choose an integral expression that can be used to find the area of R.</p> <p><b>Options:</b></p> <p><b>(A) <math>\int_0^{1.5} [f(x) - g(x)] dx</math></b></p> <p>(B) <math>\int_0^{1.5} [g(x) - f(x)] dx</math></p> <p>(C) <math>\int_0^2 [f(x) - g(x)] dx</math></p> <p>(D) <math>\int_0^2 [g(x) - x(x)] dx</math></p> |
| <p><b>Subject:</b> Music; <b>Subfield:</b> Music;</p> <p><b>Image Type:</b> Sheet Music;</p> <p><b>Difficulty:</b> Medium</p>                                                                                                                                                                                                                                                      | <p><b>Subject:</b> Marketing; <b>Subfield:</b> Market Research; <b>Image Type:</b> Plots and Charts;</p> <p><b>Difficulty:</b> Medium</p>                                                                                                                                                | <p><b>Subject:</b> Math; <b>Subfield:</b> Calculus;</p> <p><b>Image Type:</b> Mathematical Notations;</p> <p><b>Difficulty:</b> Easy</p>                                                                                                                                                                                                                                                                           |
| Health & Medicine                                                                                                                                                                                                                                                                                                                                                                  | Humanities & Social Science                                                                                                                                                                                                                                                              | Tech & Engineering                                                                                                                                                                                                                                                                                                                                                                                                 |
| <p><b>Question:</b> You are shown subtraction <i>&lt;image 1&gt;</i>, T2 weighted <i>&lt;image 2&gt;</i> and T1 weighted axial <i>&lt;image 3&gt;</i> from a screening breast MRI. What is the etiology of the finding in the left breast?</p> <p><b>Options:</b></p> <p>(A) Susceptibility artifact</p> <p>(B) Hematoma</p> <p><b>(C) Fat necrosis</b> (D) Silicone granuloma</p> | <p><b>Question:</b> In the political cartoon, the United States is seen as fulfilling which of the following roles? <i>&lt;image 1&gt;</i></p> <p><b>Option:</b></p> <p>(A) Oppressor</p> <p>(B) Imperialist</p> <p><b>(C) Savior</b> (D) Isolationist</p>                               | <p><b>Question:</b> Find the VCE for the circuit shown in <i>&lt;image 1&gt;</i>. Neglect VBE</p> <p><b>Answer: 3.75</b></p> <p><b>Explanation:</b> ...IE = [(V<sub>EE</sub>) / (R<sub>E</sub>)] = [(5 V) / (4 k-ohm)] = 1.25 mA; VCE = VCC - IERL = 10 V - (1.25 mA) 5 k-ohm; VCE = 10 V - 6.25 V = 3.75 V</p>                                                                                                    |
| <p><b>Subject:</b> Clinical Medicine; <b>Subfield:</b> Clinical Radiology; <b>Image Type:</b> Body Scans: MRI, CT.;</p> <p><b>Difficulty:</b> Hard</p>                                                                                                                                                                                                                             | <p><b>Subject:</b> History; <b>Subfield:</b> Modern History; <b>Image Type:</b> Comics and Cartoons;</p> <p><b>Difficulty:</b> Easy</p>                                                                                                                                                  | <p><b>Subject:</b> Electronics; <b>Subfield:</b> Analog electronics; <b>Image Type:</b> Diagrams;</p> <p><b>Difficulty:</b> Hard</p>                                                                                                                                                                                                                                                                               |

# Понимание физики приходит из видео




# Переход к агентам




- Агенты – это ИИ-модели, способные к рассуждению, планированию и взаимодействию с окружением для решения определённых задач, которые им задаёт пользователь
- По русски это «субъектность», т.е. Агент = Субъект
- Субъёктность — свойство индивида быть субъектом активности; применительно к человеку — способность выступать агентом (субъектом) действия и самостоятельно определять направление собственной активности, не сводимой к внешнему социальному воздействию (Википедия)

# Три вида инструментов



# Обучение агента в среде



## Agent



# Что такое Artificial General Intelligence?

1. Система, способная выполнять любую интеллектуальную задачу, которую может выполнить человек
2. Система, демонстрирующая устойчивую способность к обобщению на новые задачи без специализированной дообучающей настройки
3. Система, способная самостоятельно формировать новые абстракции и модели мира, а не только применять заранее обученные представления.
4. Система, способная полностью заменить человека на высокооплачиваемых профессиях (Кодекс OpenAI)
5. Система, с помощью которой мы заработаем 100 миллиардов \$ (договор OpenAI – Microsoft)

# Способность выполнять длинные задачи



Сейчас оценка идёт в основном на задачах программирования

<https://metr.org/>

# OpenAI GDPVal

## Manufacturing Engineer: Design 3D model of cable reel stand for assembly line

**Prompt + task context:**

**Experienced human deliverable:**



The image shows a 3D CAD model of a cable reel stand. It includes an exploded view of the components and an assembled view. The components are labeled: Reel Lock, Cable Reel, Frame (Welded), Forklift Accessible, and Reel. The assembled view shows the reel mounted on the frame, which is on a forklift-accessible base.

## Financial and Investment Analyst: Create competitor landscape for last mile delivery

**Prompt + task context:**

**Experienced human deliverable:**



The image shows a competitor landscape for last mile delivery. It includes a table with columns for Company, Service, and Key Features. The table lists several companies and their respective services and features.

## Registered Nurse: Assess skin lesion images and create consultation report

**Prompt + task context:**

**Experienced human deliverable:**



The image shows a consultation report for a skin lesion. It includes a table with columns for Date, Location, and Description. The table lists several skin lesions and their respective locations and descriptions.

## Film and Video Editor: Create high-energy intro reel with video and audio

**Prompt + task context:**

**Experienced human deliverable:**



The image shows a high-energy intro reel. It features a dark, moody background with a bright light source, possibly a sun or moon, and a silhouette of a person or object. The reel includes video and audio elements.

## Customer Service: Email response to dissatisfied customer requesting return

**Prompt + task context:**

**Experienced human deliverable:**



The image shows an email response to a dissatisfied customer requesting a return. The email is written in a professional and empathetic tone, addressing the customer's concerns and offering a solution.

## Concierge: Create week-long luxury Bahamas itinerary for family of four

**Prompt + task context:**

**Experienced human deliverable:**




The image shows a week-long luxury Bahamas itinerary for a family of four. It includes a table with columns for Day, Location, and Activity. The table lists several days of travel, including visits to various locations and activities.

## Order Clerk: Audit pricing inconsistencies in purchase orders

**Prompt + task context:**

**Experienced human deliverable:**



The image shows a spreadsheet used for auditing pricing inconsistencies in purchase orders. It includes columns for Item Number, Description, Unit Price, and Total Price. The spreadsheet lists several items and their respective prices.

## Real Estate Agent: Design sales brochure for new DC property

**Prompt + task context:**

**Experienced human deliverable:**




The image shows a sales brochure for a new DC property. It includes a table with columns for Property Name, Location, and Features. The table lists several properties and their respective locations and features.

## Recreation worker: Optimize table layout for spring vendor fair

**Prompt + task context:**

**Experienced human deliverable:**




The image shows a table layout optimization for a spring vendor fair. It includes a diagram of a table layout with various sections and booths. The diagram shows the arrangement of the table and the placement of the booths.

# OpenAI GDPVal -> GDPval-AA v2 Elo


## GDPval-AA v2 Leaderboard

Elo rating for performance on real-world work tasks · Anchored to a human baseline of 1,000 · Higher is better



----- Human Baseline (1,000)  
Not publicly available

Artificial Analysis



# ИИ-математик, ИИ-программист, ИИ-учёный

## **ИИ-математик:**

- Фронтирные ИИ-модели, в одиночку или большими комитетами (10000 агентов) начали решать «проблемы тысячелетия»


## **ИИ-программист:**

- С января 2026 года большинство коллег говорят, что теперь они весь код пишут через ИИ


## **ИИ-учёный:**

- В апреле 2026 года первая статья от российской команды прошла на A\* конференцию, в которой всё исследование и вся статья была написана мультиагентной системой
- На конференцию ICLR 2027 подано >60000 статей, больше, чем за все предыдущие года вместе взятые (2013-2026)

Мы сейчас где-то здесь




# Наш опыт – реверс-инжиниринг для САПР



Нужно геометрически точная модель, структурированная, с историей построения, с возможностью дальнейшего редактирования и переиспользования

# Наш опыт – реверс-инжиниринг для САПР





[Maksim Kolodiazhnyi et al., cadrille: Multi-modal CAD Reconstruction with Online Reinforcement Learning. ICLR 2026](#)



<https://github.com/zhemdi/cadena>

# Claude Opus 5 для CAD-задач



# Что делать исследователям?

## 1. Разработка продуктов

- Все, что может решить прикладные задачи прямо сейчас – годится.

## 2. Свои фундаментальные модели и свое железо для них.

- Скорее всего, никто СверхИнтеллектом делиться не будет, потому что это стратегическая технология круче Атомной Бомбы. Мы уже видим сигналы о закручивании гаек и ограничении доступа к моделям, а доступ к железу начали ограничивать еще раньше! –
- Свои большие модели
- Свои компактные модели

## 3. Агентские harness и методы их построения.

- Многие задачи Claude "из коробки" решает плохо, но быстро прогрессирует. Упряжь для модели X пригодится в будущем, когда свои фундаментальные модели догонят этот уровень X. Те это задел на будущее.

## 4. Бенчмарки и генераторы данных.

- Данные уже "новая нефть", и компании их скрывают, даже если делятся весами модели. Это фундамент и для своих фундаментальных моделей, и для упряжек.