
ChatGPT
狂飙
原理剖析
ZOMI

ChatGPT Talk Overview

1. BERT 模型与 GPT 模型系列
2. 强化学习加入人类反馈 RLHF 模式
3. 强化学习 PG 和 PPO 算法
4. InstructGPT 原理深度剖析

InstructGPT

原理论文解读

ChatGPT 前身 InstructGPT：基于 RLHF 微调 GPT-3

- InstructGPT 训练主要分为三个阶段。结合了监督学习和强化学习，先是监督学习让 GPT3 有一个大致的微调方向，然后用强化学习 PPO 算法来更新微调过的GPT3的参数。

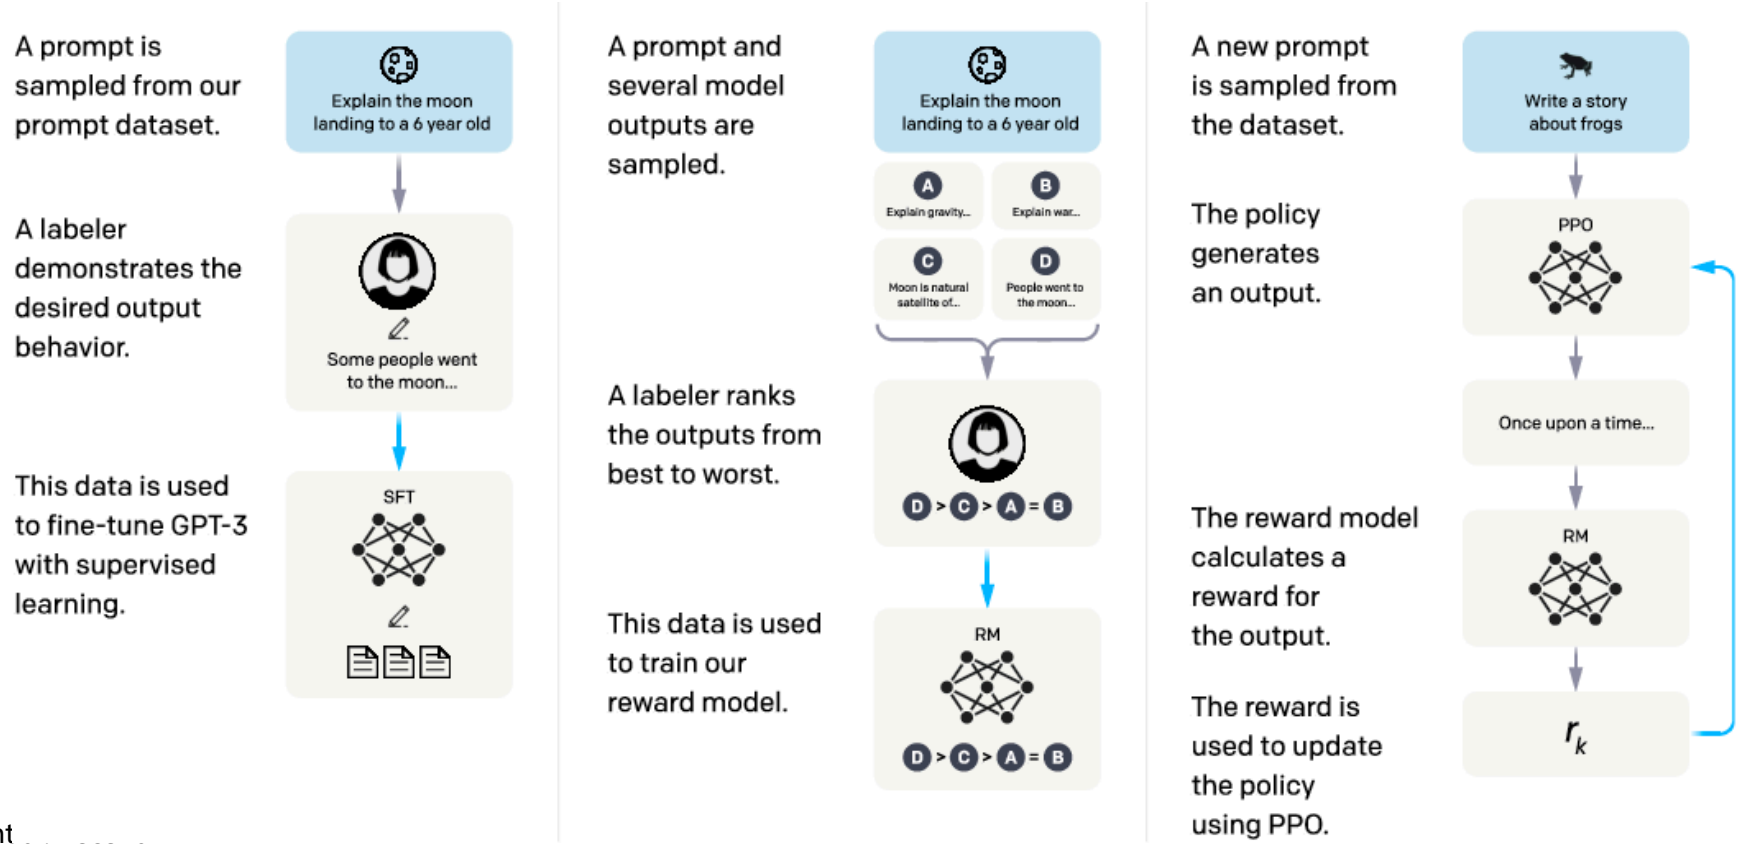

ChatGPT 前身 InstructGPT：基于 RLHF 微调 GPT-3

阶段1：利用人类的标注数据（demonstration data）去对 GPT3 进行监督训练。

1. 1）先设计了一个prompt dataset，里面有大量提示样本，给出了各种各样的任务描述；
2. 2）其次，标注团队对 prompt dataset 进行标注(本质就是人工回答问题)；
3. 3）用标注后的数据集微调 GPT3（可允许过拟合），微调后模型称为 SFT 模型（Supervised fine-tuning，SFT），具备了最基本的文本生成能力。

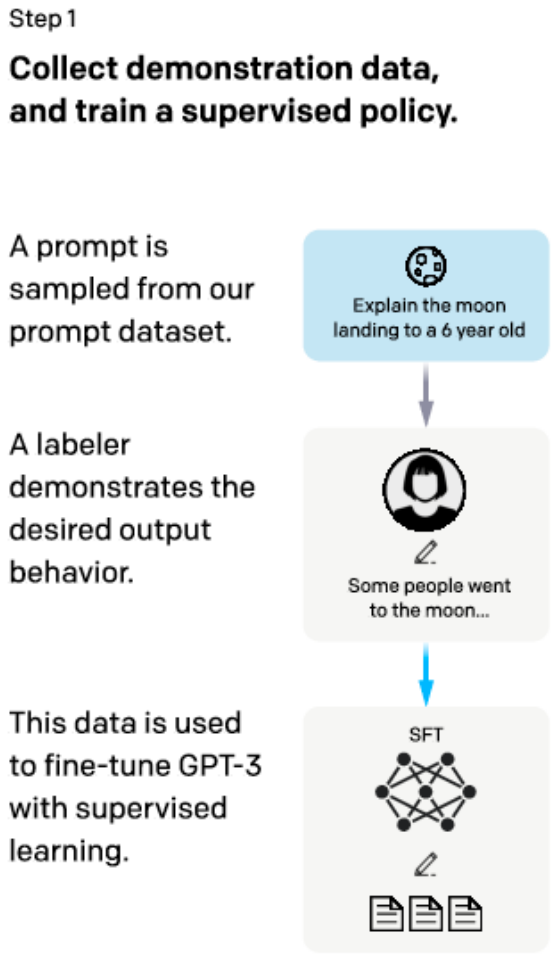

ChatGPT 前身 InstructGPT：基于 RLHF 微调 GPT-3

阶段2：通过 RLHF 思路训练奖励模型 RM

1. 1）微调后的 SFT 模型去回答 prompt dataset 问题，通过收集 4 个不同 SFT 输出而获取 4 个回答；
2. 2）接着人工对 SFT 模型生成的 4 个回答的好坏进行标注且排序；
3. 3）排序结果用来训练奖励模型RM (Reward Model)，即学习排序结果从而理解人类的偏好。

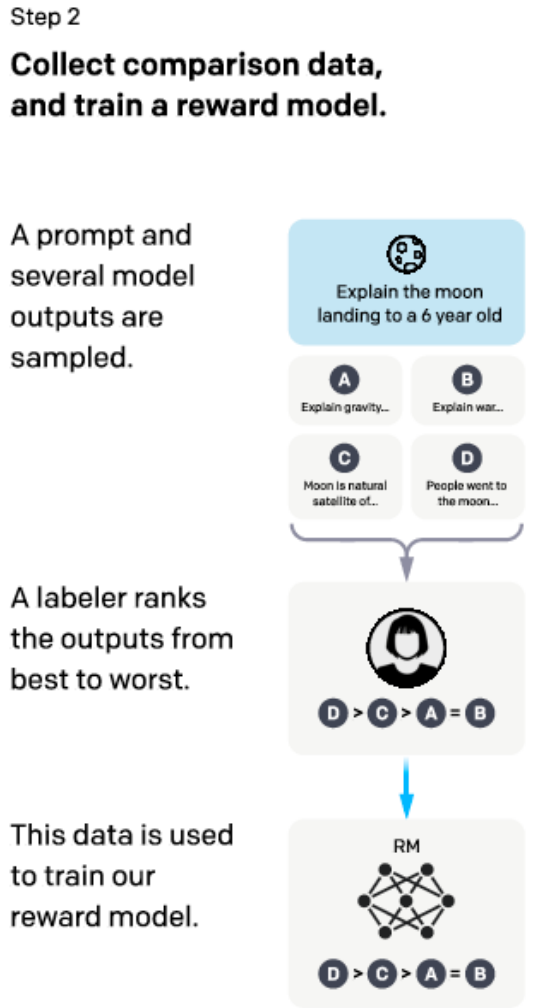

ChatGPT 前身 InstructGPT：基于 RLHF 微调 GPT-3

阶段3：通过训练好的 RM 模型预测结果且通过 PPO 算法优化 SFT 模型的策略。

1. 1）让 SFT 模型去回答 prompt dataset 问题，得到策略的输出，即生成的回答；
2. 2）此时不再让人工评估好坏，而是让阶段 2 RM 模型去给 SFT 模型的预测结果进行打分排序；
3. 3）使用 PPO 算法对 SFT 模型进行反馈更新，更新后的模型称为 PPO-ptx。

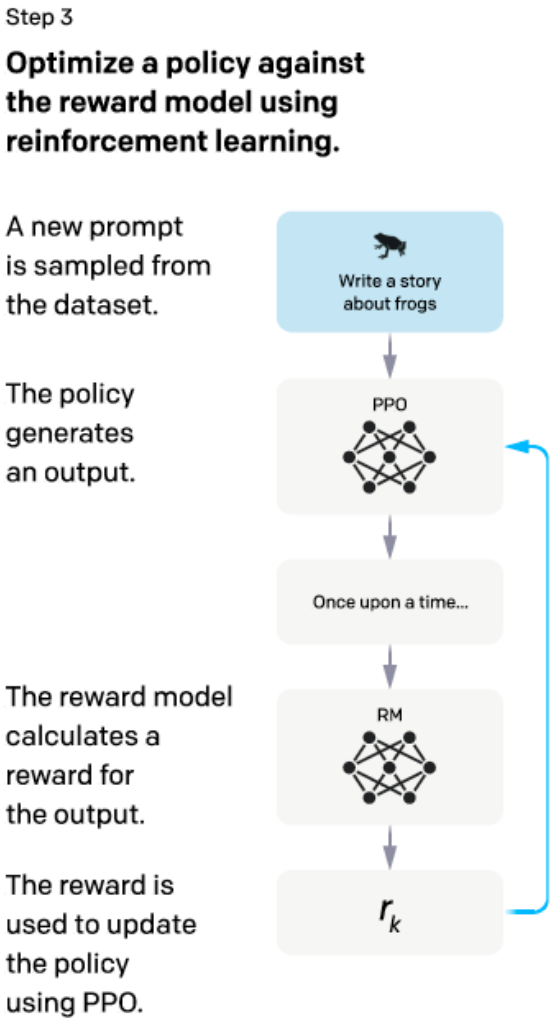

InstructGPT

原理深度剖析

阶段2：训练RM模型

- RM 核心是由人类对 SFT 生成的多个输出进行排序，再用来训练 RM。为了让 RM 学到人类偏好（即排序），可以 4 个语句两两组合分别计算 loss 再相加取均值，即分别计算 C_4^2 个损失函数：

$$\text{loss}(\theta) = -\frac{1}{\binom{K}{2}} E_{(x,y_w,y_l)\sim D}\left[\log\left(\sigma\left(r_\theta(x,y_w) - r_\theta(x,y_l)\right)\right)\right]$$

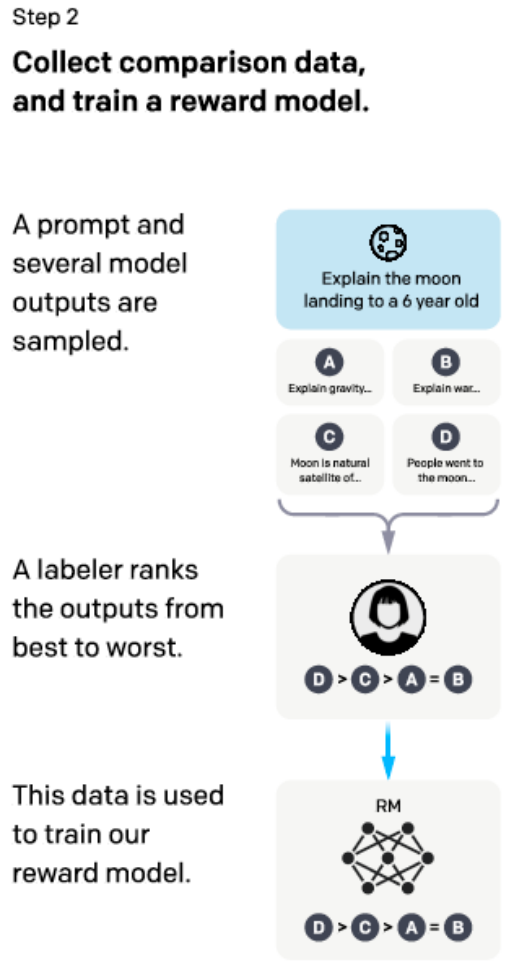

阶段2：训练RM模型

- RM 逐渐学会了给 D 这类语句打高分，给 A/B/C 这类语句打低分，从而模仿人类偏好。所谓 RLFH 人类反馈的强化学习，某种意义上来说，由人类打分来充当 Reward。

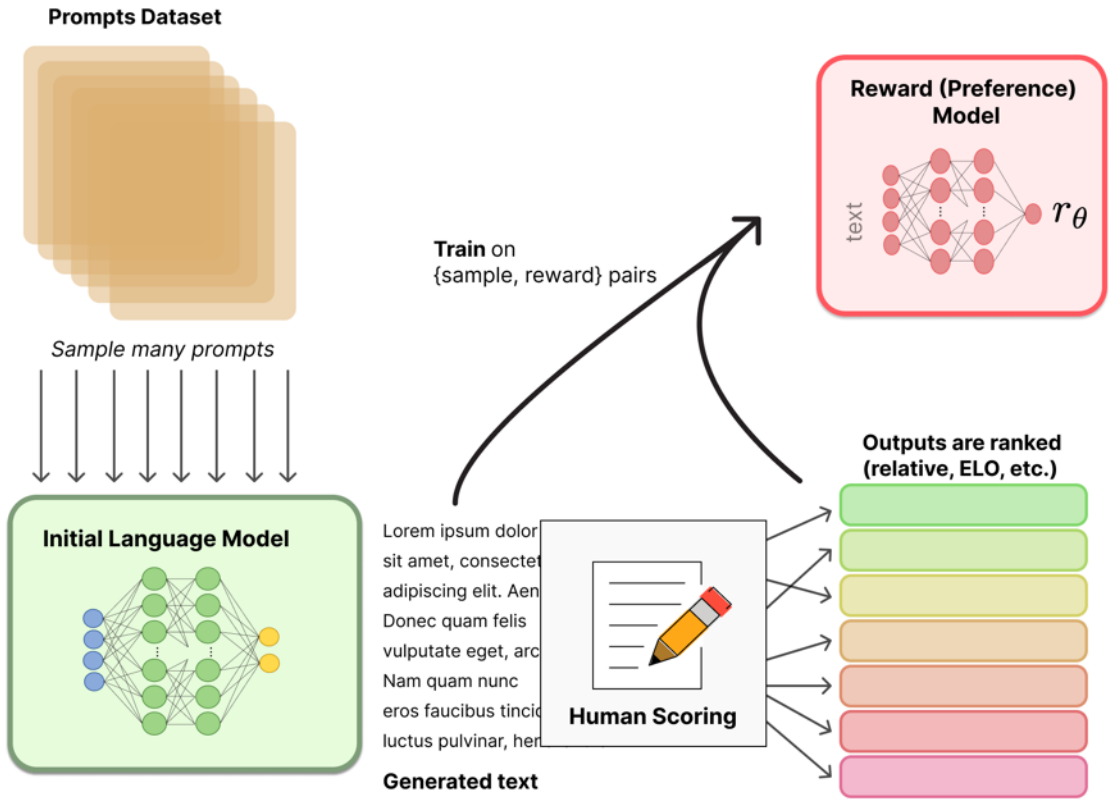

阶段3: PPO 优化策略模型

- 强化学习训练的目标函数：

$$\text{objective}(\phi) = E_{(x,y)\sim D_{\pi_\phi^{\text{RL}}}}\left[r_\theta(x,y) - \beta \log\left(\pi_\phi^{\text{RL}}(y \mid x)/\pi^{\text{SFT}}(y \mid x)\right)\right] + \gamma E_{x\sim D_{\text{pretrain}}}\left[\log(\pi_\phi^{\text{RL}}(x))\right]$$

RM 模型　　KL 散度对比策略模型 RL 和 SFT　　修正偏置项

阶段3: PPO 优化策略模型

- 迭代式的更新奖励模型 RM 和策略模型 SFT，让奖励模型 RM 对 PPO 模型输出质量的刻画愈加精确，并使得输出文本变得越来越符合人的认知。

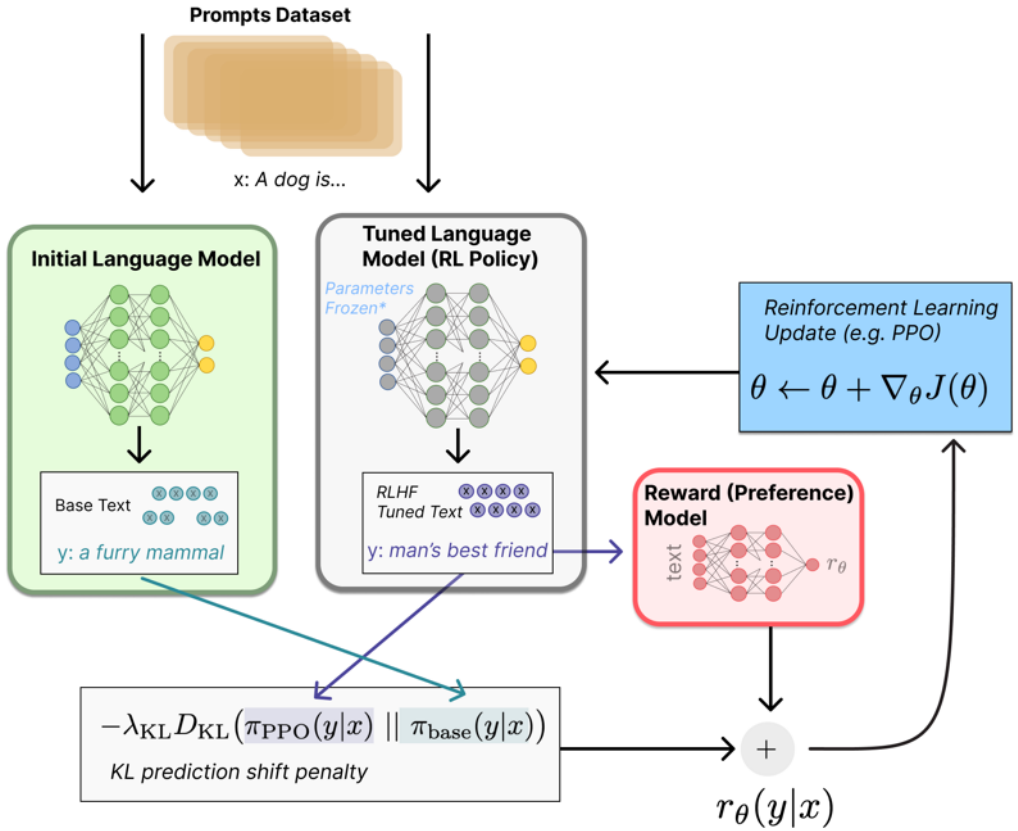

思考

思考

- 大模型通过计算的方式模拟人类的思考，类似于ChatGPT的RLHF技术是否会给世界带来新的技术产业革命？
- ChatGPT 使用了 Ray 作为细粒度的并行计算和异构计算，管理分配 RL/DL 模型完成复杂训练任务，方便利用强化学习对环境和计算任务进行控制，这对AI框架的分布式能力边界带来哪些新的冲击？
- ChatGPT 非常重数据交互，存算一体技术会不会针对ChatGPT等应用出现专用芯片和新的架构？

引用

1. Radford, Alec, et al. "Improving language understanding by generative pre-training." (2018)
2. Radford, Alec, et al. "Language models are unsupervised multitask learners." OpenAI blog 1.8 (2019): 9
3. Dale, Robert. "GPT-3: What's it good for?." Natural Language Engineering 27.1 (2021): 113-118
4. Floridi, Luciano, and Massimo Chiriatti. "GPT-3: Its nature, scope, limits, and consequences." Minds and Machines 30 (2020): 681-694.
5. Brown, Tom, et al. "Language models are few-shot learners." Advances in neural information processing systems 33 (2020): 1877-1901
6. Ouyang, Long, et al. "Training language models to follow instructions with human feedback." arXiv preprint arXiv:2203.02155 (2022)
7. https://openai.com/blog/instruction-following/
8. https://openai.com/blog/chatgpt/
9. https://sh-tsang.medium.com/review-instructgpt-training-language-models-to-follow-instructions-with-human-feedback-7fce4bf9059a
10. https://jalammar.github.io/how-gpt3-works-visualizations-animations/
11. https://jalammar.github.io/