

用 13 个参数学习推理

John X. Morris^{1,2}, Niloofar Miresghallah^{1,3}, Mark Ibrahim¹, Saeed Mahloujifar¹

¹FAIR at Meta, ²Cornell University, ³Carnegie Mellon University

近期研究表明，语言模型能够通过强化学习来学习推理。一些工作甚至使用低秩参数化来训练推理能力，但传统的 LoRA 无法缩小到模型维度以下。本文质疑秩为 1 的 LoRA 是否仍是学习推理所必需的，并提出了 TinyLoRA，一种将低秩适配器缩小到仅一个参数的方法。在本文提出的新参数化方案下，仅使用 bf16 格式的 13 个可训练参数（共 26 字节），即可将 Qwen2.5-8B 在 GSM8K 上训练至 91% 的准确率。本文发现该趋势具有普遍性：在 AIME、AMC 和 MATH500 等更具挑战性的推理学习基准测试上，使用少 1000 倍的参数仍可恢复 90% 的性能提升。值得注意的是，这种强大的性能仅在使用强化学习时才能实现：使用监督微调（SFT）训练的模型需要 100–1000 倍更大的更新才能达到相同的性能。

Date: February 9, 2026



1 引言

现代语言模型通过强化学习进行后训练，使其能够在额外的思考 token 中进行“推理”。推理训练通常通过带有可验证奖励的强化学习（RLVR）来实现，并在数学和编程等推理密集型领域中进行评估（OpenAI et al., 2024; Shao et al., 2024; Luo et al., 2025）。

尽管许多从业者对整个模型进行推理微调（通常涉及数十亿参数）（Guha et al., 2025），但以低秩适应（Low-Rank Adaptation, LoRA）（Hu et al., 2021）为代表的参数高效方法将这一需求从数十亿减少到仅数百万个“适配器”参数，降低了数个数量级。即便如此，模型更新仍然很大：对于 LLaMA-3-8B，在最小设置（秩为 1）下运行 LoRA 至少需要微调 300 万个参数（Schulman and Lab, 2025）。与先前工作（Cuccu et al., 2019）相比，这一参数数量看起来大得惊人——该工作表明某些简单场景（如 Atari 游戏）仅用六个神经元即可充分求解。

使用更少参数进行训练具有诸多优势。微调更少的参数可以降低每 GPU 的内存使用量以及分布式训练的通信开销。在推理（inference）阶段，内存中可以存储更多的 LoRA：适配器大小减少 10 倍即可同时服务 10 倍数量的 LoRA（Chen et al., 2023），从而实现大规模的高效个性化。先前工作（Biderman et al., 2024）还表明，低秩模型更新可以通过保留基座模型中的重要信息来缓解遗忘问题。

鉴于这些优势，如何实现更高的参数效率？先前工作主要集中在监督微调方面（Hu et al., 2021; Li and Liang, 2021; Zaken et al., 2022; Biderman et al., 2024）。本文观察到，在监督学习中获得良好性能需要将远多于强化学习的信息比特吸收到模型中。令人振奋的是，反之亦然：使用强化学习微调时，可以通过更小的更新达到可比的性能。这一观察促使我们提出了一种基于强化学习的替代方案，使微调所需参数比标准的基于 LoRA 的监督微调少数个数量级。

本文考虑了传统 LoRA（Hu et al., 2021）和更小的 LoRA-XS（Hu et al., 2021），它们允许将更新规模从 10^6 缩减到 10^4 个参数。在数学任务上，强化学习在低参数区间（训练参数少于 100 万）中比监督微调有效得多。在 GSM8K 数学应用题数据集上，Qwen-2.5-7B-Instruct 仅训练 10,000 个参数即从 76% 提升至 95%。由于模型在 10^4 个参数时性能下降极小，本文开发了一种新方法（TinyLoRA）将 LoRA 任意缩小：最小更新规模仅为一个参数。TinyLoRA 是 LoRA 的一种超低秩变体，可以平滑缩放到仅一个可训练参数。在 GSM8K 上使用 TinyLoRA 和分组相对策略优化（Group Relative Policy Optimization, GRPO）训练 Qwen2.5-7B-Instruct 时，**仅微调 13 个参数即达到 91% 的准确率**，更新规模仅为 26 字节。

本文表明，这种低容量的模型更新仅在强化学习的情况下才能成功，其信息密度不足以在监督微调中取得良好效果。在 GSM8K 上，使用 GRPO 训练的模型在参数少于 100 个时即可达到 90% 的准确率，而相同容量下使用监督微调训练的模型在训练集上几乎无法超越基座模型。这些发现表明，强化学习从根本上进行了比监督微调更信息密集的更新，更适合在极小更新规模区间内进行训练。

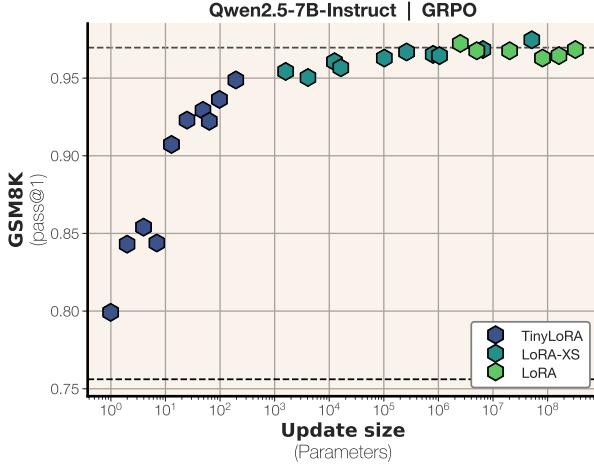


图 1 以 Qwen2.5-7B-Instruct 为基座模型, TinyLoRA 仅用 13 个参数即可在 GSM8K 上达到全量微调 5% 以内的性能。虚线表示未训练和全量微调的基线。

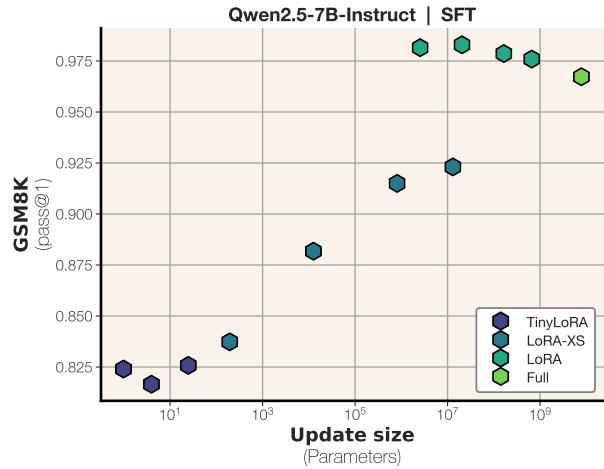


图 2 以 Qwen2.5-7B-Instruct 为基座模型, 监督微调在更新规模至少为 1M 个参数时效果最佳。

本文还在更复杂的推理学习基准测试上评估了 TinyLoRA, 包括 MATH、AIME 和 AMC。同样观察到在极低参数区间内的强大性能。作为一个数据点, 仅对 Qwen-2.5-7B-Instruct 微调 196 个参数, 在六个困难数学基准测试上平均保留了 87% 的绝对性能提升。

2 相关工作

参数高效微调。本文将 LoRA 缩放到低参数数量的进展是改进低秩适应这一持续努力的一部分, 已有大量相关方法被提出, 包括 VeRA (Kopczko et al., 2023)、VB-LoRA (Li et al., 2024b)、LoRA-XS (Balazy et al., 2025)、UniLoRA (Li et al., 2025)、AdaLoRA (Zhang et al., 2023)、LoRA Drop (Zhou et al., 2024)、NoRA (Lin et al., 2024)、WeightLoRA (Veprikov et al., 2025) 和 ShareLoRA (Song et al., 2025)。本文不主张特定的初始化方式甚至参数化方案, 而是专注于将这些技术缩放到低参数数量 ($< 10K$) 的简单方法, 而其他关于低秩适应的绝大多数工作都在 10K–10M 参数规模上进行。本文表明, 由于使用了更大的模型 (数十亿参数) 并采用强化学习而非监督微调进行训练, 更高效的参数化方案是可行的。

数据和参数约束下的学习。另一研究方向探讨推理需要多少数据, 发现一千个样本对于监督微调已经足够 (Ye et al., 2025), 而在某些设置下, 强化学习仅用一个样本即可学习 (Wang et al., 2025)。本文对更新规模与性能之间帕累托前沿的分析与过参数化模型位于低内在维度流形上这一一般性原理相关 (Li et al., 2018; Aghajanyan et al., 2020)。

监督微调与强化学习的比较。近期一系列工作将带有推理 token 的监督微调与基于策略梯度等强化学习方法进行了比较。本文对数据规模与 LoRA 性能之间关系的分析与微调缩放定律 (Zhang et al., 2024a) 和 LoRA 学习容量的研究 (Biderman et al., 2024) 相关。一些工作认为 LoRA 仅对模型进行浅层修改 (Shuttleworth et al., 2025), 另一些工作则表明强化学习的更新幅度小且相对稀疏 (Mukherjee et al., 2025)。最近, 多篇论文表明强化学习在域外泛化方面优于监督微调 (Chu et al., 2025), 遗忘更少 (Shenfeld et al., 2025), 并且通常是放大基座模型中已有的能力而非注入新的能力 (Rajani et al., 2025)。同期工作 (Schulman and Lab, 2025) 证明了 LoRA 即使在 $r = 1$ 时也能匹配全量微调的性能, 但未尝试小于 3M 的参数化方案。

3 监督微调与强化学习的更新容量

本节重新审视两种流行的学习算法——监督微调和强化学习, 并考虑使用二者分别将模型训练到良好性能所需的容量。在全文中, 我们考虑一个模型 π_θ , 它将输入 $x \in \mathcal{X}$ (在本文中为应用题) 映射到输出 $y \in \mathcal{Y}$ (解答)。

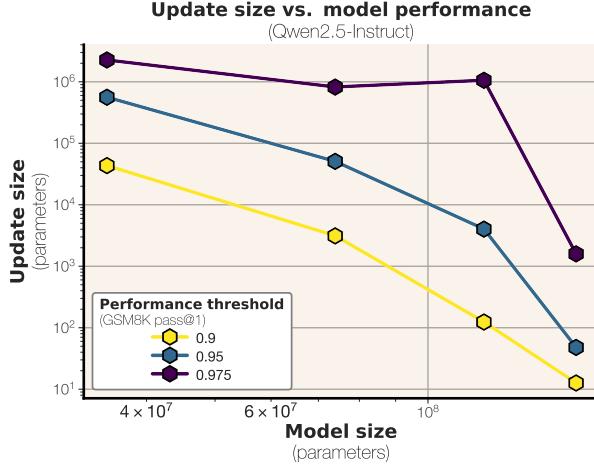


图 3 达到最大性能阈值所需的最小参数更新规模与骨干模型大小的关系。更大的模型需要更小的更新即可达到例如 95% 的峰值性能。

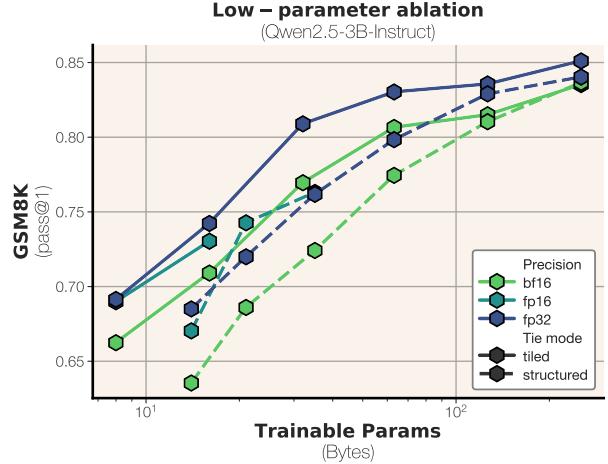


图 4 在极小更新规模 (<1KB) 下使用 Qwen2.5-3B-Instruct 的性能消融实验。令人惊讶的是，按比特计算，以 fp32 格式存储参数的性能最优。

本文研究使用下一词预测损失的监督微调：

$$\mathcal{L}_{\text{SFT}}(\theta) = -\mathbb{E}_{(x,y) \sim (\mathcal{X}, \mathcal{Y})} \left[\sum_{t=1}^{|y|} \log \pi_{\theta}(y_t | x, y_{<t}) \right]$$

以及一类称为策略梯度的强化学习算法：

$$\nabla_{\theta} J(\theta) = \mathbb{E}_{x \sim \mathcal{X}; y \sim \pi_{\theta}} \left[\sum_{t=1}^{|y|} \nabla_{\theta} \log \pi_{\theta}(y_t | x, y_{<t}) \cdot R(y) \right]$$

训练数据的信息量。考虑在样本 (x, y) 上训练模型 θ 。 (x, y) 对模型的信息量可以视为 (x, y) 在该模型下的最小描述长度 (Rissanen, 1978)。该量与 (x, y) 的采样方式无关。

对于监督微调， (x, y) 从期望奖励较高的分布 $(\mathcal{X}, \mathcal{Y})$ 中采样。为简化起见，假设奖励为二值的，且底层分布为 $(\mathcal{X}, \mathcal{Y})$ ，其中 $\mathcal{Y} \equiv \pi_{\theta}(\mathcal{X}) \mid r(\mathcal{X}, \pi_{\theta}(\mathcal{X})) = 1$ 。

对于策略梯度方法，观测数据为从 $(\mathcal{X}, (\mathcal{Y}, \mathcal{R})^k)$ 中采样的一批续写，其中 $\mathcal{Y} \equiv \pi_{\theta}(\mathcal{X})$ ， $\mathcal{R} \equiv r(\mathcal{X}, \mathcal{Y})$ 。这些样本在每个轮次使用更新后的模型重新生成。

强化学习呈现更多数据但更少信息。从某种意义上说，强化学习过程中呈现的信息似乎多于监督微调：在每个轮次中，对于每个提示 x ，我们观察到 k 个具有新熵的全新续写，而监督微调仅使用一个在各轮次中重复的续写。然而，这些信息中的大部分是噪声。没有奖励标注，续写 \mathcal{Y} 不包含用于提升任务性能的有用信号。相关信息完全在于奖励，每个提示仅有 $k \cdot H(\mathcal{R})$ 比特——当奖励为二值时以 k 为上界。

信号分离。尽管强化学习中的有用信息稀疏，但信号与噪声被清晰地分离。与奖励相关的特征与 r 相关联，与奖励无关的特征则不相关。重采样放大了这种分离——相关信号累积而不相关的变异相互抵消。

然而在监督微调中，训练信号是没有奖励标注的示范 y 。模型无法区分 y 的哪些特征与任务相关。由于缺乏信号与噪声的分离机制，监督微调必须将所有 token 视为同等具有信息量，同时存储有用的结构和无关的细节。

假说。本文假设监督微调在低参数区间表现较差，是因为最小化其目标函数要求模型吸收大量信息比特，其中只有一小部分与任务性能相关。强化学习接收到更稀疏、更纯净的信号，使其能够以更少的容量有效学习。

方法	可训练参数	最小值
FT	$\mathcal{O}(nmd^2)$	nmd^2
LoRA	$\mathcal{O}(nmr)$	$2nmd$
LoRA-XS	$\mathcal{O}(nmr^2)$	nm
VeRA	$\mathcal{O}(nm(d+r))$	$2nmd$
TinyLoRA	$\mathcal{O}(nmu)$	1

表 1 每层参数使用量对比，其中每层有 m 个适配模块、模型宽度为 d 、秩为 r 、TinyLoRA 投影维度为 u 。通过跨模块权重绑定，TinyLoRA 可将可训练参数减少至仅一个。

4 使用 TinyLoRA 的参数高效微调

强化学习的低容量需求促使我们质疑：适配器究竟可以小到什么程度，同时仍能提供足够的性能？近期工作 (Schulman and Lab, 2025; Yin et al., 2025) 观察到 LoRA 在更新规模小至 10^6 个参数时仍然有效。本节在 LoRA 和 LoRA-XS 的基础上提出 TinyLoRA，一种可缩减至仅一个可训练参数的参数高效更新方法。

4.0.1 LoRA 与 LoRA-XS

低秩适应 (LoRA) (Hu et al., 2021) 通过低秩更新来适应冻结的线性层 $W \in \mathbb{R}^{d \times k}$ ：

$$W' = W + AB$$

其中 $A \in \mathbb{R}^{d \times r}$ 和 $B \in \mathbb{R}^{r \times k}$ 为可训练参数， W 保持冻结。每个模块的可训练参数量以 $\mathcal{O}(dr)$ 缩放。将 LoRA 应用于 n 层中的 m 个模块，总参数量为 $\mathcal{O}(nmr)$ ——对于数十亿参数的模型通常达数百万 (Biderman et al., 2024; Schulman and Lab, 2025)。LoRA-XS (Bałazy et al., 2025) 将每模块参数量从 $\mathcal{O}(dr)$ 降低到 $\mathcal{O}(r^2)$ ：

$$W' = W + U\Sigma RV^\top$$

其中 $U \in \mathbb{R}^{d \times r}$ 、 $\Sigma \in \mathbb{R}^{r \times r}$ 和 $V \in \mathbb{R}^{k \times r}$ 来自 W 的截断 SVD，仅 $R \in \mathbb{R}^{r \times r}$ 为可训练参数。这可以视为学习重新组合 W 的主要奇异方向，在实践中优于随机初始化的 LoRA。

4.0.2 使用 TinyLoRA 减少可训练参数数量

由于 LoRA 的大小与模型宽度固有关系，本文提出了一种缩减可训练参数数量的新技术。该技术允许仅改变 1 个参数即可训练模型。

缩小 R 的规模。即使在 $r = 1$ 时，LoRA-XS 每个适应模块仍至少需要一个参数。本文通过将 $r \times r$ 矩阵 R 替换为一个低维可训练向量 $\mathbf{v} \in \mathbb{R}^u$ 来进一步减少参数，该向量通过固定的随机张量 $P \in \mathbb{R}^{u \times r \times r}$ 进行投影。TinyLoRA 的更新规则为：

$$W' = W + U\Sigma \left(\sum_{i=1}^u v_i P_i \right) V^\top$$

其中 U, Σ, V 来自 W 的截断 SVD， $P_i \in \mathbb{R}^{r \times r}$ 为固定的随机矩阵。每个模块仅训练 u 个参数。通过在 n 层的 m 个模块之间进行权重绑定，总可训练参数量以 $\mathcal{O}(nmu/n_{tie})$ 缩放，当所有模块共享权重时减少至仅一个参数。

参数共享。先前工作 (Dettmers et al., 2023; Biderman et al., 2024) 表明，LoRA 在同时应用于 MLP 和注意力模块时效果最佳。在 LLaMA-3 (AI@Meta, 2024) 等典型 Transformer 架构中，LoRA 在每个块中应用七次：自注意力中的 query、key、value 和 output 投影，以及 MLP 中的 up、down 和 gate 投影。

对于像 LLaMA-3 70B 这样具有 80 层的模型，即使在 $u = 1$ (或 LoRA-XS 中 $r = 1$) 的最小情况下也需要 $80 \times 7 = 560$ 个可训练参数。本文通过在模块之间共享可训练向量 \mathbf{v} 来进一步减少参数量。定义权重绑定因子 n_{tie} 为共享同一个 \mathbf{v} 的模块数量，对于 n 层、每层 m 个模块，总可训练参数为 nmu/n_{tie} 。在完全权重绑定 ($n_{tie} = nm$) 的情况下，所有模块共享同一个 \mathbf{v} ，总参数减少到仅 u 个——最少一个。TinyLoRA 与相关方法的差异见表 1。

5 实验

5.1 实验设计

实验的目标是在最小化可训练参数数量的同时提升语言模型的数学推理能力。本文在 GSM8K (Cobbe et al., 2021) (包含 7,500 道数学应用题的数据集) 和更困难的 MATH 训练集 (Hendrycks et al., 2021) 上进行评估。

本文考虑两种模型训练方式：监督微调 (SFT)，即下一词预测；以及强化学习，特别是 GRPO (Shao et al., 2024)。实验在 LLaMA-3 (AI@Meta, 2024) 和 Qwen-2.5 (Qwen et al., 2025) 系列的指令微调语言模型上进行。

本文运行四个基线：全量微调、LoRA、LoRA-XS 和 TinyLoRA。对所有 LoRA 变体测试秩 $\{1, 8, 64, 256\}$ ；对于 TinyLoRA，考虑共享 $\{1, 8, 64, 256\}$ 层。所有强化学习实验均使用精确匹配奖励。

对于 GSM8K，不使用任何 KL 惩罚，在完整数据集上训练三个轮次，每个问题 4 个样本，批量大小为 64。采样的最大生成长度为 4096。

对于 MATH 训练，本文遵循 SimpleRL (Zeng et al., 2025) 的设置，该设置包含一个更大的训练数据集，其中包括 GSM8K 和 MATH 等子集。数据按难度级别划分；本文仅在最高难度上训练，共包含 8,523 道题目。数据生成的最大提示长度为 1024，响应长度为 3072 个 token，使用 ‘boxed’ 聊天模板。保持 SimpleRL 的所有其他超参数设置：KL 系数 0.001、温度 1.0、批量大小 256、每个响应 8 次生成。

由于已知更新规模的变化会改变有效学习率 (Biderman et al., 2024; Schulman and Lab, 2025)，本文在学习率 $\{10^{-7}, 5 \times 10^{-7}, 10^{-6}, 5 \times 10^{-6}, 10^{-5}, 10^{-4}, 2 \times 10^{-4}\}$ 上进行扫描，并在每个更新规模上取三个随机种子平均后性能最优的学习率。

评估。对于仅 GSM8K 训练，在 GSM8K 验证集上评估。对于 MATH 实验，还在 SimpleRL (Zeng et al., 2025) 提出的标准数据集上进行评估：MATH500 (Hendrycks et al., 2021)、Minerva (Lewkowycz et al., 2022)、GAOKAO (Zhang et al., 2024b)、OlympiadBench (He et al., 2024)、CollegeMath (Feynman Innovations, 2024)、AIME 24 (Li et al., 2024a) 和 AMC23 (He et al., 2024)。所有数据集均为不同难度的数学应用题，来自 Qwen-Math 的标准评估 (Qwen et al., 2025)。

在 *vLLM* 中实现 *TinyLoRA*。所有强化学习实验在开源 VERL 框架 (Sheng et al., 2024) 中运行，使用 *vLLM* (Kwon et al., 2023) 进行推理 (inference)。然而，*vLLM* 的 LoRA 需要自定义内核，且仅支持最小秩为 4 的 LoRA (不支持 LoRA 变体)。本文通过修改训练流程来规避此问题：在推理 (inference) 时使用合并后的模型权重，仅在最终前向传播中使用真正的 LoRA 模型。这会在训练和推理 (inference) 之间产生数值不匹配，本文通过截断重要性采样 (Ionides, 2008; Yao et al., 2025) 来缓解。该方法允许测试新的参数高效方法，而无需为每种方法分别实现底层代码。

6 结果

6.1 初步低参数结果：TinyLoRA、LoRA-XS 和 LoRA

本文首先使用 GRPO 在 GSM8K 上训练和评估 Qwen2.5-7B-Instruct，结果如图 1 所示。可以观察到从 TinyLoRA (训练 $1-10^3$ 个参数) 到 LoRA-XS (训练 10^3-10^6 个参数) 再到 LoRA (训练 $> 10^6$ 个参数) 的相对平滑的插值。仅训练 120 个参数即可恢复 GSM8K 上 95% 的净性能提升。使用 TinyLoRA，仅训练一个参数即可获得 4% 的性能提升。

6.2 监督微调与强化学习

图 1 和图 2 分别展示了强化学习和监督微调的完整扫描结果。强化学习在低参数量时显著更高效：在 76% 的基线上，使用强化学习训练的模型在 13 个参数时达到 91% (15% 的绝对提升)，在 120 个参数时达到 95%。使用监督微调训练的模型表现差得多：13 个参数时为 83%，120 个参数时为 84%。

此外还观察到从高秩 LoRA-XS 到低秩 LoRA 的过渡不够平滑。需要注意的是，直接在答案上进行监督微调训练是一种离策略学习，当直接在模型输出上训练时动态特性可能会发生变化 (Mukherjee et al., 2025; Chen et al., 2025)。

参数量	GSM8K	MATH 500	Minerva Math	Olympiad Bench	AIME24	AMC23	平均
Qwen2.5-3B-Instruct							
(0)	76.0	55.0	18.5	21.3	2.1	23.4	32.7
16	80.9	64.0	19.9	23.0	3.0	31.5	37.1
63	85.3	64.1	20.1	26.6	7.3	36.0	39.9
252	85.4	66.4	28.3	29.3	13.3	47.5	45.0
504	86.1	66.6	28.7	30.8	16.7	47.5	46.1
8,064	87.2	67.8	28.3	30.7	10.0	47.5	45.2
129,024	86.7	67.8	29.4	32.3	10.0	55.0	46.9
(3,085,846,528)	87.0	69.0	31.7	33.1	15.0	52.2	48.0
Qwen2.5-7B-Instruct							
(0)	88.2	64.6	25.7	30.1	3.3	30.0	40.3
13	91.8	74.6	27.1	36.3	16.0	54.5	50.1
49	91.5	74.2	26.6	37.2	12.6	55.5	49.6
196	92.2	76.6	37.1	38.8	16.7	57.5	53.2
392	92.2	77.0	35.7	40.1	16.7	65.0	54.4
6,272	91.9	78.0	37.5	41.0	16.7	57.5	53.8
100,352	92.8	78.0	37.1	43.3	16.7	60.0	54.6
(7,615,487,488)	91.7	78.2	38.6	40.4	20.0	62.5	55.2
Qwen2.5-7B-Math							
(0)	65.5	63.6	12.5	25.8	13.3	42.5	37.2
196	72.5	62.0	26.5	31.4	20.0	50.0	43.7
392	86.0	74.8	31.6	37.9	26.7	60.0	52.8
6,272	87.0	77.4	28.7	40.0	16.7	67.5	52.9
100,352	87.0	78.6	32.7	39.0	30.0	62.5	55.0
(7,615,487,488)	90.2	80.2	37.5	39.0	40.0	70.0	59.5

表 2 使用 Qwen2.5 模型在数学推理任务上的表现。(0) 表示未经训练的基座模型; (*) 表示全量微调 (不使用 LoRA)。所有实验均采用 GRPO 算法并训练三个 epoch。全量微调及基线结果引自 (Zeng et al., 2025)。

6.3 在 MATH 上训练

本文研究了在 SimpleRL 训练框架 (Zeng et al., 2025) 下低参数适应方法的性能。对 7B Qwen 模型在不同更新规模上进行训练，并在数学推理任务上评估；结果如表 2 所示。考虑 $\{100, 10,000, 1M\}$ 个参数的更新，并与全量微调进行对比。

本文还可视化了训练步骤中的指标 (图 5)，包括平均奖励和平均响应长度。较大的参数量倾向于获得更高的奖励并生成更长的响应，但所有参数量都获得了一定的奖励——即使更新规模小至 16 个参数。对训练和推理 (inference) 过程中对数概率之间 KL 散度的可视化显示，训练模型与推理 (inference) 模型之间的 KL 散度可忽略不计，表明本文在每个训练步骤合并 LoRA 权重的技术运作正常。

6.4 跨骨干模型的缩放

接下来，本文将 TinyLoRA 从 XS $r = 1$ 的情况 (np 个参数) 缩减到仅一个可训练参数，在 Qwen3-8B 上对 GSM8K 进行实验。结果如图 1 所示。在 GSM8K 任务上，Qwen 在每个规模上都比 LLaMA 更具参数效率。从绝对值来看，Qwen 效率惊人，仅训练 13 个参数即达到 94.7% 的准确率。Qwen 甚至在仅 1 个参数时也取得了不错的准确率，接近 82% (比基线提升约 5%)。这一发现可能佐证了近期的观察，即 Qwen 在预训练期间可能接触过类似的样本 (Wu et al., 2025)。

即使在 LoRA-XS 的情况下 (允许用单个参数适应每层)，可训练参数的上界仍受模型中线性层总数的限制。

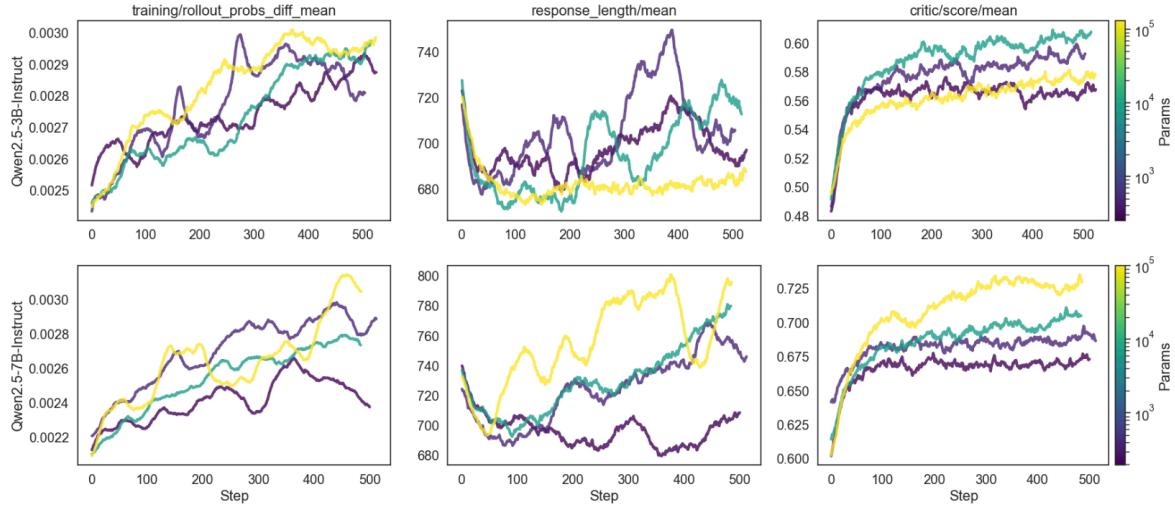


图 5 TinyLoRA 在 MATH 上训练过程中的性能。

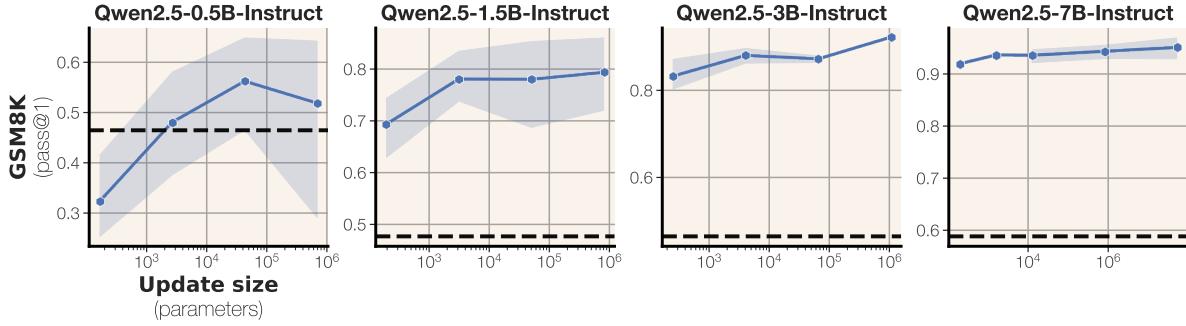


图 6 TinyLoRA 在不同骨干模型大小上的性能 (GSM8K GRPO)，虚线为未训练的基线。小规模更新仅能提升较大模型的性能。

大型模型可能包含数百个线性层，在 $r = 1$ 时允许数百字节的存储。实验上观察到，Qwen 仅用几百个参数仍然能够几乎同样好地学习。

尽管 LLaMA 具有相似的上界（来自全量微调），但在低参数设置下 LLaMA 的响应性不如 Qwen，在 1KB 的更新规模 (bf16 下训练 500 个参数) 下达到 85%。与 Qwen 不同的是，当训练少于五个参数时，LLaMA 几乎无法将性能提升至基线以上。

秩 1 到 128。图 1 展示了 Qwen 和 LLaMA 从 $r = 1$ 到 $r = 128$ 的性能。这涵盖了从 1KB ($r=1$) 到 8MB ($r=128$) 的更新规模。性能呈现一致的单调增长，表明尽管每参数的性能提升在递减，但微调额外参数在更新规模约 2MB 之前仍有帮助。

从 LoRA-XS 到 LoRA，跨骨干模型。图 6 展示了不同骨干模型大小下 LoRA 和 LoRA-XS 的结果。结果不一：LoRA-XS 在最小模型上明显优于 LoRA，与 (Balazy et al., 2025) 的发现一致。但随着模型规模增长，这一趋势变得不明显，退化为性能随可训练参数数量缩放。（需要注意的是，更大模型中 LoRA 模块的数量显著增加，这可能是关键因素。）

总体而言，低参数适应在更大模型上效果更好——在这种情况下，更小的适配器似乎更接近性能上限。图 3 绘制了 Qwen2.5-Instruct 系列不同模型的更新规模与相对性能提升的关系。趋势极为清晰：随着模型规模增长，模型可以用更少的绝对参数数量编程到其全量微调性能的 95% 以内。这些趋势表明，极大规模（万亿级）模型可能仅需少量参数即可轻松训练完成多种任务。

6.5 比特约束区间内的缩放

本文探讨了当参数量很小（数十或数百个参数）且约束在于总更新大小（以字节计）时，如何缩放 TinyLoRA。这种场景在分布式训练中很常见，因为通信模型参数更新可能是主要瓶颈。本文考虑两种参数共享策略：结构化共享，即相邻的同类型模块共享参数；以及分块共享，即相邻深度的模块共享参数，不区分类型。

不同共享策略和精度下的结果如图 4 所示。令人惊讶的是，分块共享优于结构化共享：在例如 query 投影模块之间共享参数并无益处。在全层共享和 float16 精度下，Qwen 在 GSM8K 上仍训练至 70% 的水平，绝对提升超过 10%。还注意到，即使考虑到 fp32 的更新大小为其两倍字节数，fp32 仍优于 bf16 和 float16。

7 消融实验

本文训练了若干较小模型以分析 TinyLoRA 超参数的影响。使用 GRPO 微调 Qwen-2.5-3B-Instruct 和 LLaMA-3.2-3B-Instruct，扫描冻结的 SVD 秩 r 、可训练投影维度 u 和权重绑定因子 n_{tie} （共享同一个 v 的模块数量）。

冻结秩 r 的选择。本文首先分析性能作为冻结秩 r 的函数的变化（图 7）。虽然人们可能预期保留更多奇异方向会提高表达能力，但实验发现存在收益递减：将 r 从 1 增加到 2 会带来适度的提升，但更大的值则会降低性能。本文假设更高的秩在冻结的 U 、 Σ 、 V 分量中引入了更多自由度，使得小的可训练向量 v 的优化变得更加困难。基于这些结果，所有主要实验均使用 $r = 2$ 。

u 与 n_{tie} 的权衡。在固定参数预算下，TinyLoRA 需要平衡每模块的投影维度 u 和权重绑定因子 n_{tie} 。增加 u 会提升每模块的表达能力但增加参数量；增加 n_{tie} 会减少参数量但迫使模块共享相同的 v 。图 8 绘制了这种权衡关系。性能通常随着 u 增大和 n_{tie} 减小而提升——即更具表达力的逐模块更新与更少的共享。这为从业者提供了明确的指导原则：在增加 n_{tie} 之前，先耗尽 u 的预算（降至 $u = 1$ ）。

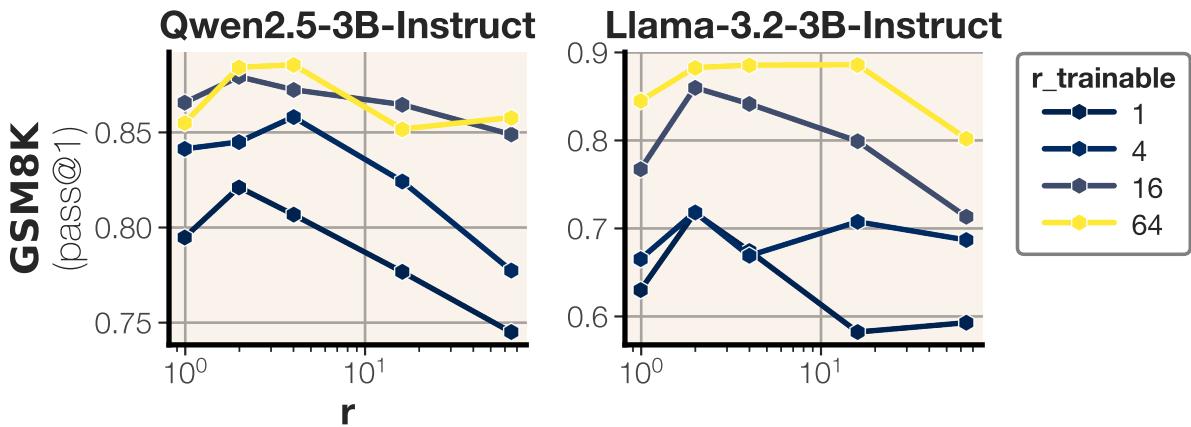


图 7 TinyLoRA 在不同冻结秩 r 和可训练秩 $r_{trainable}$ 下的性能。

8 讨论

本文的工作提出了关于微调期间模型更新规模如何随模型大小和学习目标缩放的有趣问题。

缩放趋势。本文的发现表明，随着模型规模增大，LoRA 在更少的参数量下变得更加有效。给定固定的数据集，更大的模型可以用更少的参数进行控制。这一趋势表明，随着模型继续扩大，像 TinyLoRA 这样的极致参数高效方法将越来越受欢迎。

这是如何可能的？人们可能会问，如何仅用 13 个参数就能学会解决像 GSM8K 这样的困难任务。一种理论认为，解决该任务所需的知识已经存储在模型参数中，只需改变风格即可成功完成任务。特别是，学习生成更长的输出可能仅需少量参数即可实现，且已被证明能大幅提升数学和推理任务的性能 (Shao et al., 2024)。

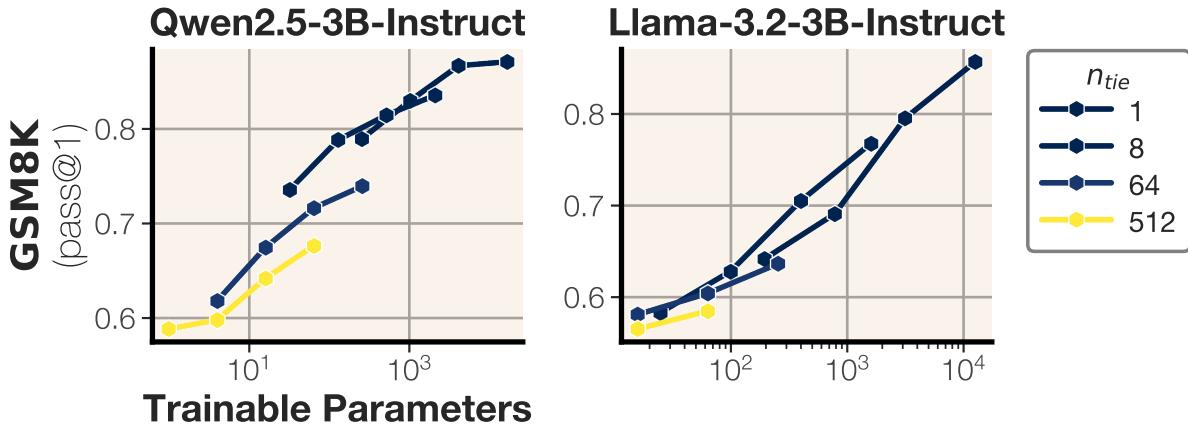


图 8 Qwen2.5-3B-Instruct 在不同绑定层数和可训练秩下的性能消融实验。

Qwen 与 LLaMA 的特异性。本文还观察到，Qwen-2.5 模型在小更新规模下通常比 LLaMA-3 表现好得多。总体而言，同系列的 Qwen 模型达到与 LLaMA 同等性能所需的更新参数量约少 10 倍。这可能与模型架构或预训练过程的细节差异有关。

数学数据集的局限性。需要指出的是，本文的发现仅限于数学数据集。许多结果似乎表明，使用强化学习，非常小的更新（数百字节量级）足以促进合理性能的推理学习。但这些发现的范围仅限于数学风格的推理，可能适用也可能不适用于科学或创意写作等其他领域。本文聚焦数学，因为它是截至 2025 年推理模型最流行的应用，但期待看到本文的发现在其他领域得到扩展和验证。

9 结论

本文提出了 TinyLoRA，并表明有效模型可以用远少于先前认为必要的参数量进行微调。TinyLoRA 的更新通常接近全量微调的性能，且可以用非常小的文件大小表示——通常总共不到 1KB。实验结果表明，某些模型可以在仅吸收极少字节的情况下学会完成特定任务，这对强化学习验证过程中实际学到了什么提出了质疑。最后，本文表明这仅在大模型上使用强化学习时才成立，在不使用强化学习或不使用大模型时效果不佳。

10 致谢

感谢 Jessy Lin、Dan Biderman、Sasha Rush、John Schulman 和 Kamalika Chaudhuri 对本文的宝贵反馈。

参考文献

- Armen Aghajanyan, Luke Zettlemoyer, and Sonal Gupta. Intrinsic dimensionality explains the effectiveness of language model fine-tuning, 2020. URL <https://arxiv.org/abs/2012.13255>.
- AI@Meta. Llama 3 model card. 2024. URL https://github.com/meta-llama/llama3/blob/main/MODEL_CARD.md.
- Klaudia Bałazy, Mohammadreza Banaei, Karl Aberer, and Jacek Tabor. Lora-xs: Low-rank adaptation with extremely small number of parameters, 2025. URL <https://arxiv.org/abs/2405.17604>.
- Dan Biderman, Jacob Portes, Jose Javier Gonzalez Ortiz, Mansheej Paul, Philip Greengard, Connor Jennings, Daniel King, Sam Havens, Vitaliy Chiley, Jonathan Frankle, Cody Blakeney, and John P. Cunningham. Lora learns less and forgets less, 2024. URL <https://arxiv.org/abs/2405.09673>.
- Howard Chen, Noam Razin, Karthik Narasimhan, and Danqi Chen. Retaining by doing: The role of on-policy data in mitigating forgetting, 2025. URL <https://arxiv.org/abs/2510.18874>.
- Lequn Chen, Zihao Ye, Yongji Wu, Danyang Zhuo, Luis Ceze, and Arvind Krishnamurthy. Punica: Multi-tenant lora serving, 2023. URL <https://arxiv.org/abs/2310.18547>.

Tianzhe Chu, Yuexiang Zhai, Jihan Yang, Shengbang Tong, Saining Xie, Dale Schuurmans, Quoc V. Le, Sergey Levine, and Yi Ma. Sft memorizes, rl generalizes: A comparative study of foundation model post-training, 2025. URL <https://arxiv.org/abs/2501.17161>.

Karl Cobbe, Vineet Kosaraju, Mohammad Bavarian, Mark Chen, Heewoo Jun, Lukasz Kaiser, Matthias Plappert, Jerry Tworek, Jacob Hilton, Reichiyo Nakano, Christopher Hesse, and John Schulman. Training verifiers to solve math word problems, 2021. URL <https://arxiv.org/abs/2110.14168>.

Giuseppe Cuccu, Julian Togelius, and Philippe Cudre-Mauroux. Playing atari with six neurons, 2019. URL <https://arxiv.org/abs/1806.01363>.

Tim Dettmers, Artidoro Pagnoni, Ari Holtzman, and Luke Zettlemoyer. Qlora: Efficient finetuning of quantized llms, 2023. URL <https://arxiv.org/abs/2305.14314>.

Feynman Innovations. Maths-college. <https://huggingface.co/datasets/ajibawa-2023/Maths-College>, 2024. revision 9eaa32a.

Etash Guha, Ryan Marten, Sedrick Keh, Negin Raoof, Georgios Smyrnis, Hritik Bansal, Marianna Nezhurina, Jean Mercat, Trung Vu, Zayne Sprague, Ashima Suvarna, Benjamin Feuer, Liangyu Chen, Zaid Khan, Eric Frankel, Sachin Grover, Caroline Choi, Niklas Muennighoff, Shiye Su, Wanjia Zhao, John Yang, Shreyas Pimpalaonkar, Kartik Sharma, Charlie Cheng-Jie Ji, Yichuan Deng, Sarah Pratt, Vivek Ramanujan, Jon Saad-Falcon, Jeffrey Li, Achal Dave, Alon Albalak, Kushal Arora, Blake Wulfe, Chinmay Hegde, Greg Durrett, Sewoong Oh, Mohit Bansal, Saadia Gabriel, Aditya Grover, Kai-Wei Chang, Vaishaal Shankar, Aaron Gokaslan, Mike A. Merrill, Tatsunori Hashimoto, Yejin Choi, Jenia Jitsev, Reinhard Heckel, Maheswaran Sathiamoorthy, Alexandros G. Dimakis, and Ludwig Schmidt. Openthoughts: Data recipes for reasoning models, 2025. URL <https://arxiv.org/abs/2506.04178>.

Chaoqun He, Renjie Luo, Yuzhuo Bai, Shengding Hu, Zhen Leng Thai, Junhao Shen, Jinyi Hu, Xu Han, Yujie Huang, Yuxiang Zhang, Jie Liu, Lei Qi, Zhiyuan Liu, and Maosong Sun. Olympiadbench: A challenging benchmark for promoting agi with olympiad-level bilingual multimodal scientific problems, 2024. URL <https://arxiv.org/abs/2402.14008>.

Dan Hendrycks, Collin Burns, Saurav Kadavath, Akul Arora, Steven Basart, Eric Tang, Dawn Song, and Jacob Steinhardt. Measuring mathematical problem solving with the math dataset, 2021. URL <https://arxiv.org/abs/2103.03874>.

Edward J. Hu, Yelong Shen, Phillip Wallis, Zeyuan Allen-Zhu, Yuanzhi Li, Shean Wang, Lu Wang, and Weizhu Chen. Lora: Low-rank adaptation of large language models, 2021. URL <https://arxiv.org/abs/2106.09685>.

Edward L. Ionides. Truncated importance sampling. *Journal of Computational and Graphical Statistics*, 17(2):295–311, 2008. doi: 10.1198/106186008X320456. URL <https://doi.org/10.1198/106186008X320456>.

Dawid J. Kopiczko, Tijmen Blankevoort, and Yuki M. Asano. Vera: Vector-based random matrix adaptation. *arXiv preprint arXiv:2310.11454*, 2023. URL <https://arxiv.org/abs/2310.11454>. Revised version v2, 16 Jan 2024.

Woosuk Kwon, Zhuohan Li, Siyuan Zhuang, Ying Sheng, Lianmin Zheng, Cody Hao Yu, Joseph E. Gonzalez, Hao Zhang, and Ion Stoica. Efficient memory management for large language model serving with pagedattention, 2023. URL <https://arxiv.org/abs/2309.06180>.

Aitor Lewkowycz, Anders Andreassen, David Dohan, Ethan Dyer, Henryk Michalewski, Vinay Ramasesh, Ambrose Slone, Cem Anil, Imanol Schlag, Theo Gutman-Solo, Yuhuai Wu, Behnam Neyshabur, Guy Gur-Ari, and Vedant Misra. Solving quantitative reasoning problems with language models, 2022. URL <https://arxiv.org/abs/2206.14858>.

Chunyuan Li, Heerad Farkhoor, Rosanne Liu, and Jason Yosinski. Measuring the intrinsic dimension of objective landscapes, 2018. URL <https://arxiv.org/abs/1804.08838>.

Jia Li, Edward Beeching, Lewis Tunstall, Ben Lipkin, Roman Soletskyi, Shengyi Costa Huang, Kashif Rasul, Longhui Yu, Albert Jiang, Ziju Shen, Zihan Qin, Bin Dong, Li Zhou, Yann Fleureau, Guillaume Lample, and Stanislas Polu. Numinamath, 2024a. URL https://github.com/project-numina/aimo-progress-prize/blob/main/report/numina_dataset.pdf.

Kaiyang Li, Shaobo Han, Qing Su, Wei Li, Zhipeng Cai, and Shihao Ji. Uni-lora: One vector is all you need. *arXiv preprint arXiv:2506.00799*, 2025. URL <https://arxiv.org/abs/2506.00799>.

Xiang Lisa Li and Percy Liang. Prefix-tuning: Optimizing continuous prompts for generation, 2021. URL <https://arxiv.org/abs/2101.00190>.

- Yang Li, Shaobo Han, and Shihao Ji. Vb-lora: Extreme parameter efficient fine-tuning with vector banks, 2024b. URL <https://arxiv.org/abs/2405.15179>.
- Cheng Lin, Lujun Li, Dezhi Li, Jie Zou, Wei Xue, and Yike Guo. Nora: Nested low-rank adaptation for efficient fine-tuning large models, 2024. URL <https://arxiv.org/abs/2408.10280>.
- Michael Luo, Sijun Tan, Justin Wong, Xiaoxiang Shi, William Y. Tang, Manan Roongta, Colin Cai, Jeffrey Luo, Li Erran Li, Raluca Ada Popa, and Ion Stoica. Deepscaler: Surpassing o1-preview with a 1.5b model by scaling rl. <https://pretty-radio-b75.notion.site/DeepScaleR-Surpassing-01-Preview-with-a-1-5B-Model-by-Scaling-RL-19681902c1468005bed8ca303013a4e2>, 2025. Notion Blog.
- Sagnik Mukherjee, Lifan Yuan, Dilek Hakkani-Tur, and Hao Peng. Reinforcement learning finetunes small subnetworks in large language models, 2025. URL <https://arxiv.org/abs/2505.11711>.
- OpenAI, :, Aaron Jaech, Adam Kalai, Adam Lerer, Adam Richardson, Ahmed El-Kishky, Aiden Low, Alec Helyar, Aleksander Madry ..., Yuchen He, Yuchen Zhang, Yunyun Wang, Zheng Shao, and Zhuohan Li. Openai o1 system card, 2024. URL <https://arxiv.org/abs/2412.16720>.
- Qwen, :, An Yang, Baosong Yang, Beichen Zhang, Binyuan Hui, Bo Zheng, Bowen Yu, Chengyuan Li, Dayiheng Liu, Fei Huang, Haoran Wei, Huan Lin, Jian Yang, Jianhong Tu, Jianwei Zhang, Jianxin Yang, Jiaxi Yang, Jingren Zhou, Junyang Lin, Kai Dang, Keming Lu, Keqin Bao, Kexin Yang, Le Yu, Mei Li, Mingfeng Xue, Pei Zhang, Qin Zhu, Rui Men, Runji Lin, Tianhao Li, Tianyi Tang, Tingyu Xia, Xingzhang Ren, Xuancheng Ren, Yang Fan, Yang Su, Yichang Zhang, Yu Wan, Yuqiong Liu, Zeyu Cui, Zhenru Zhang, and Zihan Qiu. Qwen2.5 technical report, 2025. URL <https://arxiv.org/abs/2412.15115>.
- Neel Rajani, Aryo Pradipta Gema, Seraphina Goldfarb-Tarrant, and Ivan Titov. Scalpel vs. hammer: Grpo amplifies existing capabilities, sft replaces them, 2025. URL <https://arxiv.org/abs/2507.10616>.
- Jorma Rissanen. Modeling by shortest data description. *Automatica*, 14(5):465–471, 1978.
- John Schulman and Thinking Machines Lab. Lora without regret. *Thinking Machines Lab: Connectionism*, 2025. doi: 10.64434/tml.20250929. <https://thinkingmachines.ai/blog/lora/>.
- Zhihong Shao, Peiyi Wang, Qihao Zhu, Runxin Xu, Junxiao Song, Xiao Bi, Haowei Zhang, Mingchuan Zhang, Y. K. Li, Y. Wu, and Daya Guo. Deepseekmath: Pushing the limits of mathematical reasoning in open language models, 2024. URL <https://arxiv.org/abs/2402.03300>.
- Idan Shenfeld, Jyothish Pari, and Pukit Agrawal. Rl's razor: Why online reinforcement learning forgets less, 2025. URL <https://arxiv.org/abs/2509.04259>.
- Guangming Sheng, Chi Zhang, Zilingfeng Ye, Xibin Wu, Wang Zhang, Ru Zhang, Yanghua Peng, Haibin Lin, and Chuan Wu. Hybridflow: A flexible and efficient rlhf framework. *arXiv preprint arXiv: 2409.19256*, 2024.
- Reece Shuttleworth, Jacob Andreas, Antonio Torralba, and Pratyusha Sharma. Lora vs full fine-tuning: An illusion of equivalence, 2025. URL <https://arxiv.org/abs/2410.21228>.
- Yurun Song, Junchen Zhao, Ian G. Harris, and Sangeetha Abdu Jyothi. Sharelora: Parameter efficient and robust large language model fine-tuning via shared low-rank adaptation, 2025. URL <https://arxiv.org/abs/2406.10785>.
- Andrey Veprikov, Vladimir Solodkin, Alexander Zyl, Andrey Savchenko, and Aleksandr Beznosikov. Weightlora: Keep only necessary adapters, 2025. URL <https://arxiv.org/abs/2506.02724>.
- Yiping Wang, Qing Yang, Zhiyuan Zeng, Liliang Ren, Liyuan Liu, Baolin Peng, Hao Cheng, Xuehai He, Kuan Wang, Jianfeng Gao, Weizhu Chen, Shuohang Wang, Simon Shaolei Du, and Yelong Shen. Reinforcement learning for reasoning in large language models with one training example, 2025. URL <https://arxiv.org/abs/2504.20571>.
- Mingqi Wu, Zhihao Zhang, Qiaole Dong, Zhiheng Xi, Jun Zhao, Senjie Jin, Xiaoran Fan, Yuhao Zhou, Huijie Lv, Ming Zhang, Yanwei Fu, Qin Liu, Songyang Zhang, and Qi Zhang. Reasoning or memorization? unreliable results of reinforcement learning due to data contamination, 2025. URL <https://arxiv.org/abs/2507.10532>.
- Feng Yao, Liyuan Liu, Dinghuai Zhang, Chengyu Dong, Jingbo Shang, and Jianfeng Gao. Your efficient rl framework secretly brings you off-policy rl training, August 2025. URL <https://fengyao.notion.site/off-policy-rl>.
- Yixin Ye, Zhen Huang, Yang Xiao, Ethan Chern, Shijie Xia, and Pengfei Liu. Limo: Less is more for reasoning, 2025. URL <https://arxiv.org/abs/2502.03387>.

- Qingyu Yin, Yulun Wu, Zhennan Shen, Sunbowen Li, Zhilin Wang, Yanshu Li, Chak Tou Leong, Jiale Kang, and Jinjin Gu. Evaluating parameter efficient methods for rlvr, 2025. URL <https://arxiv.org/abs/2512.23165>.
- Elad Ben Zaken, Shauli Ravfogel, and Yoav Goldberg. Bitfit: Simple parameter-efficient fine-tuning for transformer-based masked language-models, 2022. URL <https://arxiv.org/abs/2106.10199>.
- Weihao Zeng, Yuzhen Huang, Qian Liu, Wei Liu, Keqing He, Zejun Ma, and Junxian He. Simplerl-zoo: Investigating and taming zero reinforcement learning for open base models in the wild, 2025. URL <https://arxiv.org/abs/2503.18892>.
- Biao Zhang, Zhongtao Liu, Colin Cherry, and Orhan Firat. When scaling meets llm finetuning: The effect of data, model and finetuning method, 2024a. URL <https://arxiv.org/abs/2402.17193>.
- Qingru Zhang, Minshuo Chen, Alexander Bukharin, Nikos Karampatziakis, Pengcheng He, Yu Cheng, Weizhu Chen, and Tuo Zhao. Adalora: Adaptive budget allocation for parameter-efficient fine-tuning, 2023. URL <https://arxiv.org/abs/2303.10512>.
- Xiaotian Zhang, Chunyang Li, Yi Zong, Zhengyu Ying, Liang He, and Xipeng Qiu. Evaluating the performance of large language models on gaokao benchmark, 2024b. URL <https://arxiv.org/abs/2305.12474>.
- Hongyun Zhou, Xiangyu Lu, Wang Xu, Conghui Zhu, Tiejun Zhao, and Muyun Yang. Lora-drop: Efficient lora parameter pruning based on output evaluation, 2024. URL <https://arxiv.org/abs/2402.07721>.

A 附录

A.1 额外消融实验

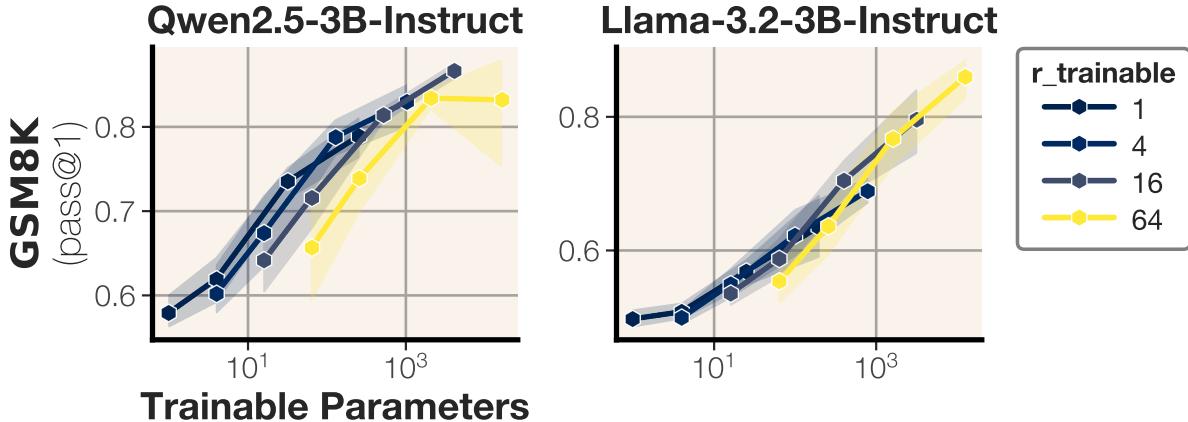


图 9 Qwen2.5-3B-Instruct 在不同绑定层数和秩 r 下的性能消融实验。

本文进行了多项消融实验以确定“花费”可训练参数的最佳方式：是拥有更多的共享参数更好，还是更少但独立的参数更好？在 GSM8K 上对 3B 版本的 Qwen-2.5 和 LLaMA-3.2 扫描不同的 $r_{trainable}$ 值。令人惊讶的是，在匹配参数量的情况下，较低的 $r_{trainable}$ 值反而获得了更高的性能，表明参数更适合投入到更少但独立的参数上。此外再次观察到，在相同更新规模下 Qwen 远优于 LLaMA：仅训练 100 个参数时，LLaMA 达到约 60% 的准确率，而 Qwen 在 3 个随机种子上平均达到 74%。