

Simplex LoRA: Expand important adapters

Давыденко Григорий, Шалыгин Игорь

Научный руководитель: Безносиков А. Н.

Научный консультант: Веприков А. С.

Московский физико-технический институт

18 мая 2025 г.

Содержание доклада

- ① Введение и мотивация
- ② Постановка задачи
- ③ Основная идея SimplexLoRA
- ④ Методы изменения рангов матриц
- ⑤ Результаты экспериментов
- ⑥ Заключение и дальнейшие планы

Введение и мотивация

Low-rank adaptation (LoRA):

- Тюнинг линейных слоев больших моделей через низкоранговые матрицы $A \in \mathbb{R}^{n \times r}$ и $B \in \mathbb{R}^{r \times m}$ ($r \ll m, n$):

$$W_i \longrightarrow W_i + A_i \cdot B_i$$

- Эффективность за счет снижения числа обучаемых параметров

Проблема:

- В данном алгоритме мы не регулируем ранги адаптеров
- Хотим ответить на вопрос:

Выходы каких слоев вносят наибольшее отклонение от оптимума и должны быть скорректированы сильнее?

Идея и алгоритм SimplexLoRA

Добавим к каждому адаптеру вес ω .

Ограничения: $\sum_{i=1}^n \omega_i = n$ и $\omega_i \geq 0$ (масштабированный симплекс).

За время обучения мы совершаём раз в несколько шагов изменения рангов LoRA в соответствии с их обучаемыми весами:

- ① Сначала все ранги равны гиперпараметру $r_i^{(0)} = r^0$, веса - $\omega_i^{(0)} = 1$
- ② После шага в оптимизаторе $\omega^{(k)} = proj_{simplex}(\omega^{(k)})$
- ③ Через фиксированное количество шагов x меняем ранги LoRA согласно новым весам:

$$r_i^{(u)} = ceil(r^0 \cdot \omega_i^{(u \cdot x)})$$

- ④ Пункты 2 и 3 повторяем несколько раз.
- ⑤ Запускаем стандартное обучение LoRA с подобранными рангами.

Расширение рангов

Пусть есть LoRA адаптер с $A_{old} \in \mathbb{C}^{n \times r_{old}}$ и $B_{old} \in \mathbb{C}^{r_{old} \times m}$, который мы хотим расширить до ранга $r > r_{old}$

- **Наивный подход:**

Дополнение обученных матриц А и В нормальной и нулевой

$$A = [A_{old} \ N_{n \times (r - r_{old})}] \quad B = [B_{old} \ 0_{m \times (r - r_{old})}]$$

- **Через QR-разложение:**

QR-разложения: $A_{old} = Q_A \cdot R_A$

$$A = [Q_A \ (I - Q_A \cdot Q_A^*) \cdot N_{n \times (r - r_{old})}] = [Q_A \ N_{n \times (r - r_{old})}^{new}]$$

$$B = [B_{old} \cdot R_A^* \ 0_{m \times r_{old}}]$$

В обоих случаях у нас соблюдается равенство $A_{old} \cdot B_{old} = A \cdot B$

Сжатие рангов

Пусть есть LoRA адаптер с $A_{old} \in \mathbb{C}^{n \times r_{old}}$ и $B_{old} \in \mathbb{C}^{r_{old} \times m}$, который мы хотим уменьшить до положительного ранга $r < r_{old}$

Ставим оптимизационную задачу:

$$\|A_{old} \cdot B_{old}^* - A \cdot B^*\|_F \longrightarrow \min_{A \in \mathbb{C}^{n \times r}, B \in \mathbb{C}^{r \times m}}$$

Решение: эффективно обрезать SVD разложение $A_{old} \cdot B_{old}^*$.

$$A_{old} = Q_A \cdot R_A \quad B_{old} = Q_B \cdot R_B \quad U \cdot \Sigma \cdot V^* = SVD(R_A \cdot R_B^*)$$


$$\begin{cases} U \in \mathbb{C}^{r_{old} \times r_{old}} \\ V \in \mathbb{C}^{r_{old} \times r_{old}} \\ \Sigma \in \mathbb{C}^{r_{old} \times r_{old}} \end{cases} \longrightarrow \begin{cases} U_r \in \mathbb{C}^{r_{old} \times r} \\ V_r \in \mathbb{C}^{r_{old} \times r} \\ \Sigma_r \in \mathbb{C}^{r \times r} \end{cases}$$

Итоговые матрицы А и В:

$$A = Q_A \cdot U_r \quad B = \Sigma_r \cdot V_r^* \cdot Q_B^*$$

Результаты экспериментов

Рис.: Итоговое распределение рангов после 3 шагов проекции.



Результаты экспериментов

Таблица: Тюнинг гиперпараметров на примере Roberta(185M) GLUE RTE

Метод	Ранг r_0			
	1	2	4	8
LoRA	0.79422 1e-4	0.78700 8e-5	0.83032 5e-4	0.84477 5e-4
SimplexLoRA	0.81588 1e-5	0.82310 5e-5	0.81588 5e-5	0.81949 1e-4

Обращаем внимание на следующие параметры:

- ① learning rate
- ② warmup steps
- ③ количество операций изменений рангов

Во время проведения экспериментов выявлено, что данные параметры имеют наибольшее влияние на целевые метрики.

Заключение и дальнейшие планы

- ① Досчитываем эксперименты и метрики, ведем учет в таблицах
- ② Дописываем статью на конференцию ACL
- ③ Готовим pull request в библиотеку PEFT

Источники

- LoRA: Low-Rank Adaptation of Large Language Models
- AdaLoRA: Adaptive Budget Allocation for Parameter-Efficient Fine-Tuning
- Large-scale Multiclass Support Vector Machine Training via Euclidean Projection onto the Simplex