

# Федеративное обучение и сверхпараметризация в моделях

Эйдлин Иван

Научный руководитель: А. В. Гасников

МФТИ

22 апреля 2025 г.

# Начало работы

## Этапы исследования

- Первый этап - исследование работ по обобщенной гладкости [1], [2], [4]
- Второй этап - изучение сверхпараметризации [3], [5]

## Мотивация текущего исследования

- Исследование началось с изучения свойств функций с обобщенной гладкостью
- Занялась техника рестартов и ее теоретическое обоснование
- Обнаружена связь между обобщенной гладкостью и сверхпараметризацией
- В рамках этого этапа: применение рестартов к сверхпараметризованным моделям

# Обобщённая гладкость

## Определение $(L_0, L_1)$ -гладкости

Функция  $f : \mathbb{R}^d \rightarrow \mathbb{R}$  называется  $(L_0, L_1)$ -гладкой, если для любых  $x, y \in \mathbb{R}^d$  с условием  $\|y - x\| \leq \frac{1}{L_1}$ :

$$\|\nabla f(y) - \nabla f(x)\| \leq (L_0 + L_1 \|\nabla f(x)\|) \|y - x\| \quad (1)$$

## Теоретические гарантии


Для функций с  $(L_0, L_1)$ -гладкостью градиентный спуск с адаптивным шагом  $\eta_k = (L_0 + L_1 \|\nabla f(x^k)\|)^{-1}$  гарантирует:

- линейную сходимость, если  $\|\nabla f(x^k)\| \geq \frac{L_0}{L_1}$
- сублинейную сходимость, если  $\|\nabla f(x^{N-1})\| < \frac{L_0}{L_1}$


# Техника рестартов

## Определение

Метод рестартов для ускоренного градиентного спуска - подход, при котором периодически происходит сброс накопленного момента и переоценка параметров метода.



Константа Липшица  $L(x)$



Контурная карта


# Особенности оптимизации сверхпараметризованных моделей I

## Определение сверхпараметризации

Модель считается сверхпараметризованной, когда число параметров  $d$  значительно превышает количество обучающих примеров  $n$ :  $d \gg n$ .

## Геометрия пространства решений

- Множество глобальных минимумов образует многообразие
- При  $d > n$  существует бесконечное множество интерполирующих решений
- Различные решения обладают разной обобщающей способностью



# Особенности оптимизации сверхпараметризованных моделей II

## Феномен интерполяции и обобщения

- Парадокс: переобучение не наблюдается даже при  $d \gg n$
- Существуют "хорошие" и "плохие" минимумы
- Градиентный спуск обладает имплицитной регуляризацией

## Проблемы стандартных оптимизаторов

- Плато в ландшафте потерь (медленная сходимость)
- Осцилляции вблизи решения
- Сложность выбора размера шага
- Чувствительность к начальной инициализации

## Связь с теорией

- Функции потерь сверхпараметризованных моделей проявляют свойства обобщённой гладкости
- Условие  $(L_0, L_1)$ -гладкости актуально в окрестности многообразия решений
- Локальные свойства ландшафта требуют адаптивных методов

## Теоретические гарантии

Для функций с  $(L_0, L_1)$ -гладкостью градиентный спуск с адаптивным шагом имеет линейную сходимость при  $\|\nabla f(x^k)\| \geq \frac{L_0}{L_1}$ .

# Выбор архитектуры для первых экспериментов

## ResNet как объект исследования

- ResNet-18 с дополнительными полносвязными слоями (увеличение параметров)
- Модификация архитектуры: замена стандартного классификатора на последовательность

$$\text{fc} = \text{Linear}(512 \rightarrow 1024) \rightarrow \text{ReLU} \rightarrow \\ \text{Linear}(1024 \rightarrow 1024) \rightarrow \text{ReLU} \rightarrow \text{Linear}(1024 \rightarrow 10) \quad (2)$$

## Формализация задачи оптимизации

$$\min_{\theta \in \mathbb{R}^d} \mathcal{L}(\theta) = \frac{1}{n} \sum_{i=1}^n \ell(f_\theta(x_i), y_i) \quad (3)$$

где  $f_\theta$  - ResNet с параметрами  $\theta$ ,  $\ell$  - функция потерь (кросс-энтропия),  $(x_i, y_i)_{i=1}^n$  - обучающие данные.

## Критерии определения момента рестарта в эксперименте

- ① Фиксированный период (каждые 15 эпох):

$$\text{Restart if: } \text{iteration} - \text{last\_restart} \geq 15 \quad (4)$$

- ② На основе нормы градиента на валидационной выборке:

$$\text{Restart if: } \frac{\|\nabla \mathcal{L}_{\text{val}}(x_k)\|}{\|\nabla \mathcal{L}_{\text{val}}(x_{k-p})\|} > 2.0 \quad (5)$$

- ③ На основе изменения функции потерь на валидации:

$$\text{Restart if: } \mathcal{L}_{\text{val}}(x_k) > \mathcal{L}_{\text{val}}(x_{k-p}) \quad (6)$$

# Сравнение AdamW и AdamW с рестартами





График потерь и точности

- AdamW: лучшая точность на валидации
- Меньший разрыв между обучающей и валидационной точностью




t-SNE визуализация траекторий

- Разные минимумы в пространстве параметров
- Более эффективное исследование пространства


# Рестарты против переобучения

## Эксперимент по регрессии с большим количеством параметров

- Задача регрессии на зашумленных данных:  
 $y = \sin(x) + 0.5 \cos(2x) + 0.1x^2 + \varepsilon$
- Сверхпараметризованная нейронная сеть (параметров  $\gg$  точек)
- Сравнение оптимизации с рестартами и без них



высокая дисперсия, шумное



низкая дисперсия, гладкое поведение

# Эксперименты с YOLO моделями

## Сравнение на задаче детекции объектов

- Архитектура YOLO для задачи детекции объектов
- Сравнение стандартного SGD и SGD с рестартами
- Анализ влияния периода рестартов на качество детекции
- Исследование динамики обучения с помощью t-SNE визуализации

## Результаты

- Улучшение mAP (mean Average Precision) на 1-2%
- Ускорение сходимости по числу итераций

# Заключение и дальнейшие планы

## Основные результаты

- Разработана теория применения рестартов для сверхпараметризованных моделей
- Предложены критерии определения момента рестарта
- Продемонстрировано улучшение обобщающей способности на ResNet

## Направления дальнейших исследований

- Расширение на другие архитектуры (трансформеры, диффузионные модели)
- Исследование комбинации рестартов с методами понижения размерности
- Глубокий анализ влияния рестартов на федеративное обучение
- Выявление оптимальных критериев рестарта

# Литература

- [1] S. S. Ablaev, A. N. Beznosikov, A. V. Gasnikov, D. M. Dvinskikh, A. V. Lobanov, S. M. Puchinin, and F. S. Stonyakin. On some works of boris teodorovich polyak on the convergence of gradient methods and their development. *Computational Mathematics and Mathematical Physics*, 64(4):635–675, Apr. 2024.
- [2] A. Lobanov, A. Gasnikov, E. Gorbunov, and M. Takáč. Linear convergence rate in convex setup is possible! gradient descent method variants under  $(l_0, l_1)$ -smoothness, 2025.
- [3] P. Nakkiran, G. Kaplun, Y. Bansal, T. Yang, B. Barak, and I. Sutskever. Deep double descent: Where bigger models and more data hurt, 2019.
- [4] Z. Tovmasyan, G. Malinovsky, L. Condat, and P. Richtárik. Revisiting stochastic proximal point methods: Generalized smoothness and similarity, 2025.
- [5] C. Zhang, S. Bengio, M. Hardt, B. Recht, and O. Vinyals. Understanding deep learning requires rethinking generalization, 2017.

# Спасибо за внимание!