

О стохастическом экстраградиентном методе для вариационных неравенств

Дмитрий Ковалев

Московский физико-технический институт
Физтех-школа прикладной математики и информатики
Кафедра интеллектуальных систем

Научный руководитель: д.ф-м.н. Гасников А.В.

Вариационное неравенство

Найти вектор $x^* \in \mathbb{R}^d$, удовлетворяющий

$$g(x) - g(x^*) + \langle F(x^*), x - x^* \rangle \geq 0 \text{ для всех } x \in \mathbb{R}^d$$

- ▶ $g : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ – μ -сильно выпуклая замкнутая функция
- ▶ $F : \mathbb{R}^d \rightarrow \mathbb{R}^d$ – монотонный L -липшицев оператор

Стохастическое вариационное неравенство

Найти вектор $x^* \in \mathbb{R}^d$, удовлетворяющий

$$g(x) - g(x^*) + \langle F(x^*), x - x^* \rangle \geq 0 \text{ для всех } x \in \mathbb{R}^d$$

$$F(x) = \mathbb{E}_\xi[F(x; \xi)]$$

- ▶ ξ – случайный вектор
- ▶ $F(x; \xi)$ – почти наверное монотонный
 L -липшицев оператор

Пример: стохастическая минимизация

$$\min_{x \in \mathbb{R}^d} \mathbb{E}_\xi [f(x; \xi)] + g(x)$$

- ▶ $f(x; \xi) : \mathbb{R}^d \rightarrow \mathbb{R}$ – почти наверное выпуклая
 L -гладкая функция

$$F(x; \xi) = \nabla f(x; \xi)$$

Пример: стохастическая седловая задача

$$\min_{x \in \mathbb{R}^{d_x}} \max_{y \in \mathbb{R}^{d_y}} \mathbb{E}_\xi [f(x, y; \xi)] + g_x(x) - g_y(y)$$

- ▶ $g_x(x) : \mathbb{R}^{d_x} \rightarrow \mathbb{R} \cup \{+\infty\}$ и $g_y(y) : \mathbb{R}^{d_y} \rightarrow \mathbb{R} \cup \{+\infty\}$ –
 μ -сильно выпуклые функции
- ▶ $f(x, y; \xi) : \mathbb{R}^{d_x} \times \mathbb{R}^{d_y} \rightarrow \mathbb{R}$ – почти наверное
выпуклая по x и вогнутая по y L -гладкая функция

$$F((x, y); \xi) = \begin{bmatrix} \nabla_x f(x, y; \xi) \\ -\nabla_y f(x, y; \xi) \end{bmatrix}, \quad g((x, y)) = g_x(x) + g_y(y)$$

Экстраградиентный алгоритм

промежуточная точка

Algorithm 1 Extragradient Method for Variational Inequalities.

1: **Parameters:** $x^0 \in \mathcal{K}$, stepsize $\eta > 0$

2: **for** $t = 0, 1, 2, \dots$ **do**

3: $y^t = \text{prox}_{\eta g}(x^t - \eta F(x^t))$ ← градиентный шаг из x^t

4: $x^{t+1} = \text{prox}_{\eta g}(x^t - \eta F(y^t))$

5: **end for**

градиентный шаг из x^t с градиентом взятым в y^t

Стохастический экстраградиентный алгоритм

Algorithm 1 Extragradient Method for Variational Inequalities.

- 1: **Parameters:** $x^0 \in \mathcal{K}$, stepsize $\eta > 0$
- 2: **for** $t = 0, 1, 2, \dots$ **do**
- 3: $y^t = \text{prox}_{\eta g}(x^t - \eta F(x^t)) \leftarrow F(x^t; \xi_1^t)$
- 4: $x^{t+1} = \text{prox}_{\eta g}(y^t - \eta F(y^t)) \leftarrow F(y^t; \xi_2^t)$
- 5: **end for**

Векторы ξ_1^t и ξ_2^t равны или выбраны независимо?

Экстраградиент с независимыми сэмплами

Anatoli Juditsky, Arkadi Nemirovski, Claire Tauvel

Solving variational inequalities with stochastic mirror-prox algorithm.
Stochastic Systems 1.1 (2011): 17-58.

- ▶ требует равномерную ограниченность шума на всей области определения для сходимости
- ▶ расходится на простой билинейной седловой задаче когда область определения неограничена

Предлагаемый подход: экстраградиент с одинаковыми сэмплами

Algorithm 2 Stochastic Extragradient Method for Variational Inequalities.

```
1: Parameters:  $x^0 \in \mathcal{K}$ , stepsize  $\eta > 0$ 
2: for  $t = 0, 1, 2, \dots$  do
3:   Sample  $\xi^t \leftarrow$  
4:    $y^t = \text{prox}_{\eta g}(x^t - \eta F(x^t; \xi^t))$ 
5:    $x^{t+1} = \text{prox}_{\eta g}(x^t - \eta F(y^t; \xi^t))$ 
6: end for
```

требует ограниченность шума ТОЛЬКО в оптимуме!

Основная теорема

Теорема. Пусть $g: \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ – μ -сильно выпуклая замкнутая функция, $F(\cdot; \xi): \mathbb{R}^d \rightarrow \mathbb{R}^d$ – почти наверное монотонный L -липшицев оператор с ограниченной в оптимуме x^* дисперсией $\mathbb{E}\|F(x^*; \xi) - \mathbb{E}[F(x^*; \xi)]\|^2 \leq \sigma^2$. Тогда для любого $\eta \leq 1/(2L)$ выполнено

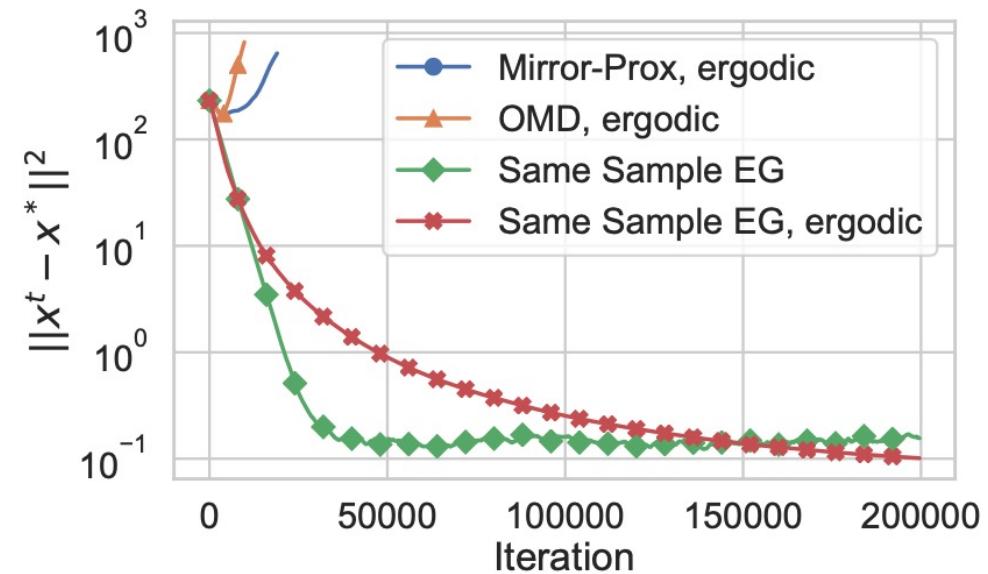
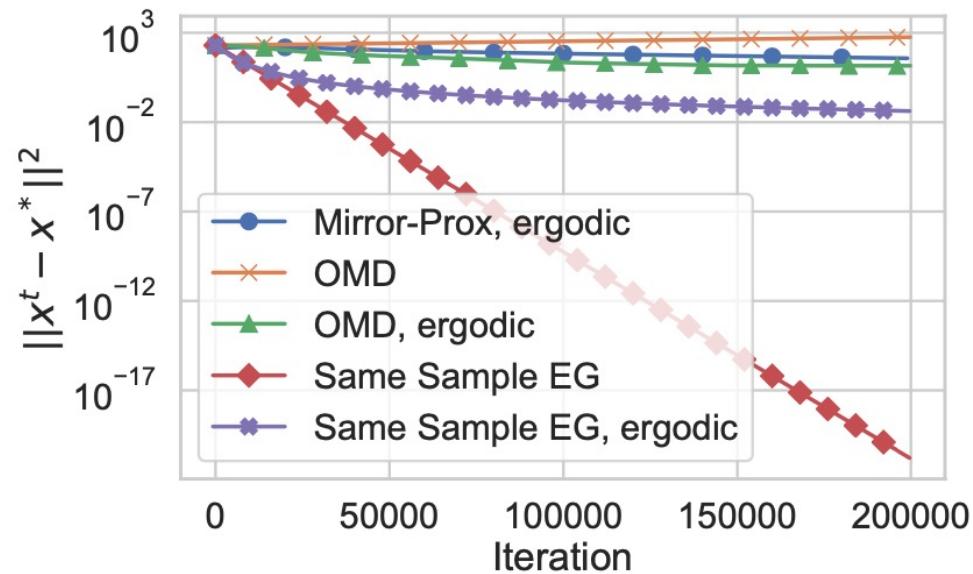
$$\mathbb{E}\|x^t - x^*\|^2 \leq \left(1 - \frac{2\eta\mu}{3}\right)^t \|x^0 - x^*\|^2 + \frac{3\eta\sigma^2}{\mu}.$$

Основная теорема

Следствие. Чтобы достичь точности $\|x^t - x^*\|^2 \leq \epsilon$, требуется следующее число итераций:

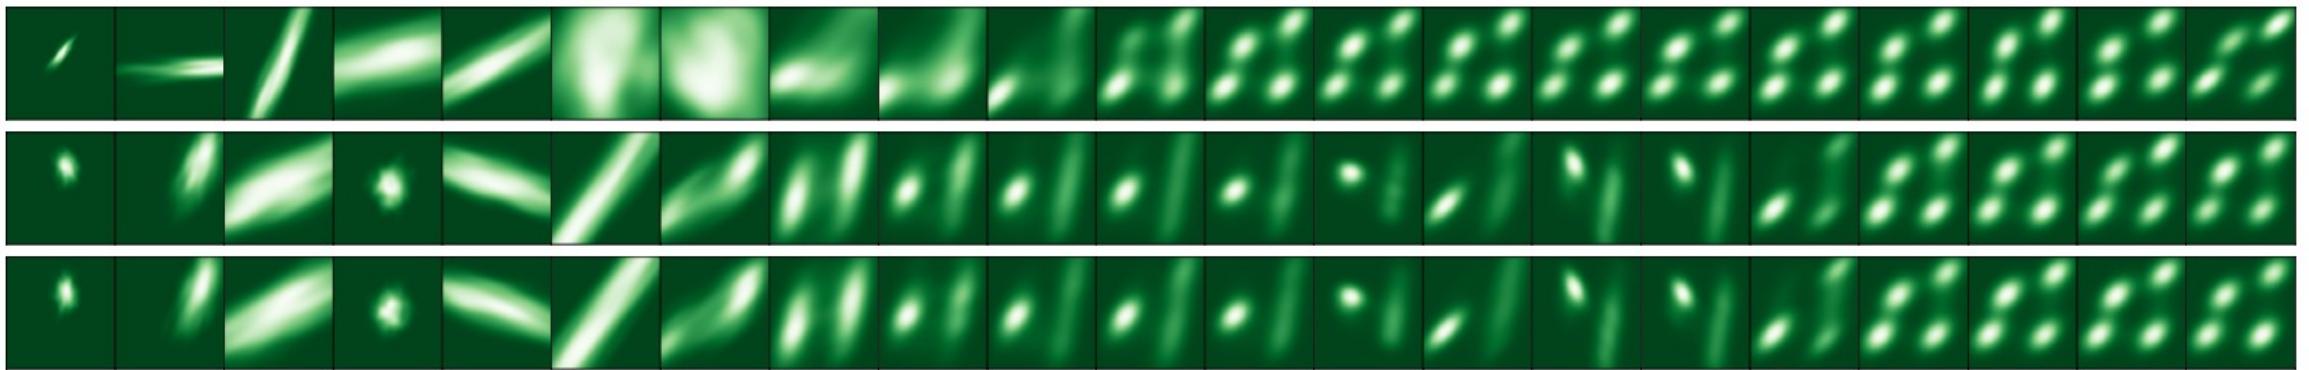
$$t = \mathcal{O} \left(\max \left\{ \frac{L}{\mu}, \frac{\sigma^2}{\epsilon \mu^2} \right\} \log \frac{\|x^0 - x^*\|^2}{\epsilon} \right).$$

Эксперимент: билинейная седловая задача



Сходимость алгоритмов Mirror-Prox (Juditsky et al., 2011), Optimistic Mirror Descent (Gidel et al., 2019) и предложенного алгоритма Same Sample EG. Слева: стохастическая седловая задача $\min_x \max_y \sum_{i=1}^n x^\top \mathbf{B}_i y$. Так как в оптимуме шум равен 0, предложенный алгоритм сходится линейно, в отличие от медленной сходимости алгоритмов (Juditsky et al., 2011) и (Gidel et al., 2019). Справа: стохастическая седловая задача с линейными членами. Так как шум в оптимуме не равен 0, (Juditsky et al., 2011) и (Gidel et al., 2019) расходятся в отличие от предложенного метода.

Эксперимент: генерация смеси гауссиан



Верхний ряд: предложенный алгоритм. Средний ряд: градиентный спуск-подъем. Нижний ряд: (Juditsky et al., 2011).

Эксперимент: GAN, CelebA



Результаты обучения self attention GAN с помощью алгоритмов Adam (верхний ряд) и ExtraAdam (нижний ряд) за два прохода по данным. Представлены результаты для трех лучших шагов 10^{-2} , $2 \cdot 10^{-3}$, $4 \cdot 10^{-3}$ в порядке от левого к правому.

Выносится на защиту

- ▶ Предложен новый вариант стохастического экстраградиентного метода для вариационных неравенств
- ▶ Доказано теоретическое превосходство предложенного метода над известными результатами
- ▶ Проведены численные эксперименты, показывающие практическую эффективность предложенного подхода

Избранные публикации за время обучения

- Dmitry Kovalev, Elnur Gasanov, Peter Richtarik, Alexander Gasnikov
Lower Bounds and Optimal Algorithms for Smooth and Strongly Convex Decentralized Optimization Over Time-Varying Networks
arXiv preprint arXiv:2106.04469, 2021
- Dmitry Kovalev, Egor Shulgin, Peter Richtarik, Alexander Rogozin, Alexander Gasnikov
ADOM: Accelerated Decentralized Optimization Method for Time-Varying Networks
Proceedings of the 38th International Conference on Machine Learning, 2021
- Dmitry Kovalev, Adil Salim, Peter Richtarik
Optimal and Practical Algorithms for Smooth and Strongly Convex Decentralized Optimization
34th Conference on Neural Information Processing Systems, 2020
- Eduard Gorbunov, Dmitry Kovalev, Dmitry Makarenko, Peter Richtarik
Linearly Converging Error Compensated SGD
34th Conference on Neural Information Processing Systems, 2020

Избранные публикации за время обучения

- Filip Hanzely, Dmitry Kovalev, Peter Richtarik
*Variance Reduced Coordinate Descent with Acceleration:
New Method With a Surprising Application to Finite-Sum Problems*
Proceedings of the 37th International Conference on Machine Learning, 2020
- Zhize Li, Dmitry Kovalev, Xun Qian, Peter Richtarik
Acceleration for Compressed Gradient Descent in Distributed and Federated Optimization
Proceedings of the 37th International Conference on Machine Learning, 2020
- Grigory Malinovskiy, Dmitry Kovalev, Elnur Gasanov, Laurent Condat, Peter Richtarik
From Local SGD to Local Fixed-Point Methods for Federated Learning
Proceedings of the 37th International Conference on Machine Learning, 2020
- Konstantin Mishchenko, Dmitry Kovalev, Egor Shulgin, Peter Richtarik, Yura Malitsky
Revisiting Stochastic Extragradient
Proceedings of the 23rd International Conference on Artificial Intelligence and Statistics, 2020