

# Стохастические вариационные неравенства и седловые задачи

Александр Безносиков

Обучение, понимание и оптимизация в моделях искусственного интеллекта, г. Пушкин

25 июня 2022

# Вариационное Неравенство (ВН)

Пусть дано выпуклое множество  $\mathcal{Z} \subseteq \mathbb{R}^n$  и оператор  $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$ . Тогда сформулируем задачу поиска решения ВН:

## Задача ВН

Найти  $z^* \in \mathcal{Z}$  такую, что:

$$\langle F(z^*), z - z^* \rangle \geq 0, \quad \forall z \in \mathcal{Z}.$$

# Частные случаи: минимизация

- Пусть  $F(z) = \nabla f(z)$  – градиент функции  $f$ ,  $Z = \mathbb{R}^n$ .
- $z^*$  – решение соответствующего ВН  $\Leftrightarrow \nabla f(z^*) = 0$ .  
⇐ Очевидно.  
⇒ Пусть  $z^*$  – решение ВН и  $\nabla f(z^*) \neq 0$ , тогда должно быть выполнено

$$\langle \nabla f(z^*), z - z^* \rangle \geq 0, \quad \forall z \in Z.$$

Рассмотрим  $z = z^* - \nabla f(z^*)$ , тогда

$$\langle \nabla f(z^*), z - z^* \rangle = -\|\nabla f(z^*)\|^2 < 0,$$

что противоречит предположению о том, что  $z^*$  – решение ВН.

- Суть: если функция  $f$  выпуклая, то  $z^*$  – минимум; если функция  $f$  невыпуклая, то  $z^*$  – стационарная точка.
- Аналогично, можно поступить и с задачами условной оптимизации ( $Z \neq \mathbb{R}^n$ ).

# Частные случаи: минимизация

- Пусть  $F(z) = \nabla f(z)$  – градиент функции  $f$ ,  $Z = \mathbb{R}^n$ .

- $z^*$  – решение соответствующего ВН  $\Leftrightarrow \nabla f(z^*) = 0$ .

⇐ Очевидно.

⇒ Пусть  $z^*$  – решение ВН и  $\nabla f(z^*) \neq 0$ , тогда должно быть выполнено

$$\langle \nabla f(z^*), z - z^* \rangle \geq 0, \quad \forall z \in Z.$$

Рассмотрим  $z = z^* - \nabla f(z^*)$ , тогда

$$\langle \nabla f(z^*), z - z^* \rangle = -\|\nabla f(z^*)\|^2 < 0,$$

что противоречит предположению о том, что  $z^*$  – решение ВН.

- Суть: если функция  $f$  выпуклая, то  $z^*$  – минимум; если функция  $f$  невыпуклая, то  $z^*$  – стационарная точка.

- Аналогично, можно поступить и с задачами условной оптимизации ( $Z \neq \mathbb{R}^n$ ).

# Частные случаи: минимизация

- Пусть  $F(z) = \nabla f(z)$  – градиент функции  $f$ ,  $Z = \mathbb{R}^n$ .
- $z^*$  – решение соответствующего ВН  $\Leftrightarrow \nabla f(z^*) = 0$ .  
     $\Leftarrow$  Очевидно.  
     $\Rightarrow$  Пусть  $z^*$  – решение ВН и  $\nabla f(z^*) \neq 0$ , тогда должно быть выполнено

$$\langle \nabla f(z^*), z - z^* \rangle \geq 0, \quad \forall z \in Z.$$

Рассмотрим  $z = z^* - \nabla f(z^*)$ , тогда

$$\langle \nabla f(z^*), z - z^* \rangle = -\|\nabla f(z^*)\|^2 < 0,$$

что противоречит предположению о том, что  $z^*$  – решение ВН.

- Суть: если функция  $f$  выпуклая, то  $z^*$  – минимум; если функция  $f$  невыпуклая, то  $z^*$  – стационарная точка.
- Аналогично, можно поступить и с задачами условной оптимизации ( $Z \neq \mathbb{R}^n$ ).

# Частные случаи: минимизация

- Пусть  $F(z) = \nabla f(z)$  – градиент функции  $f$ ,  $Z = \mathbb{R}^n$ .
- $z^*$  – решение соответствующего ВН  $\Leftrightarrow \nabla f(z^*) = 0$ .  
     $\Leftarrow$  Очевидно.  
     $\Rightarrow$  Пусть  $z^*$  – решение ВН и  $\nabla f(z^*) \neq 0$ , тогда должно быть выполнено

$$\langle \nabla f(z^*), z - z^* \rangle \geq 0, \quad \forall z \in Z.$$

Рассмотрим  $z = z^* - \nabla f(z^*)$ , тогда

$$\langle \nabla f(z^*), z - z^* \rangle = -\|\nabla f(z^*)\|^2 < 0,$$

что противоречит предположению о том, что  $z^*$  – решение ВН.

- Суть: если функция  $f$  выпуклая, то  $z^*$  – минимум; если функция  $f$  невыпуклая, то  $z^*$  – стационарная точка.
- Аналогично, можно поступить и с задачами условной оптимизации ( $Z \neq \mathbb{R}^n$ ).

## Частные случаи: минимизация

- Решение ВН неравенства:

$$\langle F(z^*), z - z^* \rangle \geq 0.$$

- Подставим  $F(z^*) = \nabla f(z^*)$ :

$$\langle \nabla f(z^*), z - z^* \rangle = \langle F(z^*), z - z^* \rangle \geq 0.$$

- Воспользуемся определением выпуклости:

$$\begin{aligned} f(z) - f(z^*) &\geq \langle \nabla f(z^*), z - z^* \rangle \\ &= \langle F(z^*), z - z^* \rangle \\ &\geq 0. \end{aligned}$$

## Частные случаи: минимизация

- Решение ВН неравенства:

$$\langle F(z^*), z - z^* \rangle \geq 0.$$

- Подставим  $F(z^*) = \nabla f(z^*)$ :

$$\langle \nabla f(z^*), z - z^* \rangle = \langle F(z^*), z - z^* \rangle \geq 0.$$

- Воспользуемся определением выпуклости:

$$\begin{aligned} f(z) - f(z^*) &\geq \langle \nabla f(z^*), z - z^* \rangle \\ &= \langle F(z^*), z - z^* \rangle \\ &\geq 0. \end{aligned}$$

## Частные случаи: минимизация

- Решение ВН неравенства:

$$\langle F(z^*), z - z^* \rangle \geq 0.$$

- Подставим  $F(z^*) = \nabla f(z^*)$ :

$$\langle \nabla f(z^*), z - z^* \rangle = \langle F(z^*), z - z^* \rangle \geq 0.$$

- Воспользуемся определением выпуклости:

$$\begin{aligned} f(z) - f(z^*) &\geq \langle \nabla f(z^*), z - z^* \rangle \\ &= \langle F(z^*), z - z^* \rangle \\ &\geq 0. \end{aligned}$$

## Частные случаи: седловые задачи

- Пусть  $\mathcal{Z} = \mathcal{X} \times \mathcal{Y}$ , где  $\mathcal{X} \subseteq \mathbb{R}^{n_x}$  и  $\mathcal{Y} \subseteq \mathbb{R}^{n_y}$ , также дана выпукло-вогнутая функция  $g(x, y)$ .
- Определим

$$F(z) = F(x, y) = \begin{pmatrix} \nabla_x g(x, y) \\ -\nabla_y g(x, y) \end{pmatrix}.$$

## Частные случаи: седловые задачи

- Решение соответствующего ВН:

$$\left\langle \begin{pmatrix} \nabla_x g(x^*, y^*) \\ -\nabla_y g(x^*, y^*) \end{pmatrix}, \begin{pmatrix} x - x^* \\ y - y^* \end{pmatrix} \right\rangle = \langle F(z^*), z - z^* \rangle \geq 0.$$

- Перепишем удобнее:

$$\begin{aligned} & \langle \nabla_x g(x^*, y^*), x - x^* \rangle + \langle -\nabla_y g(x^*, y^*), y - y^* \rangle \\ &= \left\langle \begin{pmatrix} \nabla_x g(x^*, y^*) \\ -\nabla_y g(x^*, y^*) \end{pmatrix}, \begin{pmatrix} x - x^* \\ y - y^* \end{pmatrix} \right\rangle \\ &= \langle F(z^*), z - z^* \rangle \geq 0. \end{aligned}$$

- Выпуклость по  $x$ , вогнутость по  $y$  дают

$$\begin{aligned} & [g(x, y^*) - g(x^*, y^*)] + [g(x^*, y^*) - g(x^*, y)] \\ & \geq \langle F(z^*), z - z^* \rangle \geq 0. \end{aligned}$$

## Частные случаи: седловые задачи

- Решение соответствующего ВН:

$$\left\langle \begin{pmatrix} \nabla_x g(x^*, y^*) \\ -\nabla_y g(x^*, y^*) \end{pmatrix}, \begin{pmatrix} x - x^* \\ y - y^* \end{pmatrix} \right\rangle = \langle F(z^*), z - z^* \rangle \geq 0.$$

- Перепишем удобнее:

$$\begin{aligned} & \langle \nabla_x g(x^*, y^*), x - x^* \rangle + \langle -\nabla_y g(x^*, y^*), y - y^* \rangle \\ &= \left\langle \begin{pmatrix} \nabla_x g(x^*, y^*) \\ -\nabla_y g(x^*, y^*) \end{pmatrix}, \begin{pmatrix} x - x^* \\ y - y^* \end{pmatrix} \right\rangle \\ &= \langle F(z^*), z - z^* \rangle \geq 0. \end{aligned}$$

- Выпуклость по  $x$ , вогнутость по  $y$  дают

$$\begin{aligned} & [g(x, y^*) - g(x^*, y^*)] + [g(x^*, y^*) - g(x^*, y)] \\ & \geq \langle F(z^*), z - z^* \rangle \geq 0. \end{aligned}$$

## Частные случаи: седловые задачи

- Решение соответствующего ВН:

$$\left\langle \begin{pmatrix} \nabla_x g(x^*, y^*) \\ -\nabla_y g(x^*, y^*) \end{pmatrix}, \begin{pmatrix} x - x^* \\ y - y^* \end{pmatrix} \right\rangle = \langle F(z^*), z - z^* \rangle \geq 0.$$

- Перепишем удобнее:

$$\begin{aligned} & \langle \nabla_x g(x^*, y^*), x - x^* \rangle + \langle -\nabla_y g(x^*, y^*), y - y^* \rangle \\ &= \left\langle \begin{pmatrix} \nabla_x g(x^*, y^*) \\ -\nabla_y g(x^*, y^*) \end{pmatrix}, \begin{pmatrix} x - x^* \\ y - y^* \end{pmatrix} \right\rangle \\ &= \langle F(z^*), z - z^* \rangle \geq 0. \end{aligned}$$

- Выпуклость по  $x$ , вогнутость по  $y$  дают

$$\begin{aligned} & [g(x, y^*) - g(x^*, y^*)] + [g(x^*, y^*) - g(x^*, y)] \\ & \geq \langle F(z^*), z - z^* \rangle \geq 0. \end{aligned}$$

## Частные случаи: седловые задачи

- Тогда решение соответствующего вариационного неравенства  $z^* = (x^*, y^*)$  есть **седловая точка**:

$$g(x^*, y) \leq g(x^*, y^*) \leq g(x, y^*), \quad \forall x \in \mathcal{X}, y \in \mathcal{Y}.$$

- Другая формулировка седловой задачи:

Задача поиска седловой точки

Найти  $x^* \in \mathcal{X}$ ,  $y^* \in \mathcal{Y}$  решение задачи:

$$\min_{x \in \mathcal{X}} \max_{y \in \mathcal{Y}} g(x, y).$$

## Частные случаи: седловые задачи

- Тогда решение соответствующего вариационного неравенства  $z^* = (x^*, y^*)$  есть **седловая точка**:

$$g(x^*, y) \leq g(x^*, y^*) \leq g(x, y^*), \quad \forall x \in \mathcal{X}, y \in \mathcal{Y}.$$

- Другая формулировка седловой задачи:

### Задача поиска седловой точки

Найти  $x^* \in \mathcal{X}$ ,  $y^* \in \mathcal{Y}$  решение задачи:

$$\min_{x \in \mathcal{X}} \max_{y \in \mathcal{Y}} g(x, y).$$

# Частные случаи: задача поиска стационарной точки оператора

- Найти  $z^* \in \mathcal{Z}$  такую, что:

$$T(z^*) = z^*,$$

где оператор  $T : \mathbb{R}^n \rightarrow \mathbb{R}^n$ .

- Определим

$$F(z) = T(z) - z.$$

- Тогда

$$F(z^*) = 0$$

или

$$\langle F(z^*), z - z^* \rangle \geq 0.$$

# Классические задачи

- Билинейная задача на вероятностном симплексе:

$$\min_{x \in \mathbb{R}} \max_{y \in \mathbb{R}} x^T A y,$$

$\Delta^{n_x}$  – вероятностный симплекс размера  $n_x$  (все компоненты вектора неотрицательные и в сумме дают 1 – интуиция: распределение вероятности).

- Имеет массу применений, в первую очередь в экономике и теории игр. Еще эту задачу называют матричной игрой или задачей поиска равновесия – Нэшевского эквilibриума.

# Примеры: минимизация с ограничениями и множители Лагранжа

- Задача минимизации с выпуклыми ограничениями:

$$\min_{\substack{x \in \mathbb{R}^n \\ \mathbf{g}(x)=0}} f(x).$$

- Запись в виде задачи с множителями Лагранжа

$$\min_{x \in \mathbb{R}^n} \max_{y \in \mathbb{R}^{\text{len}(\mathbf{g})}} f(x) + y^T \mathbf{g}(x).$$

# Примеры: робастная оптимизация/сопоставительный подход

- Рассмотрим следующий модифицированную функцию потерь:

$$\max_{\|\delta_n\|_2 \leq \epsilon} f(w, \delta) := \max_{\|\delta\|_2 \leq \epsilon} \frac{1}{N} \sum_{n=1}^N l(g(w, x_n + \delta_n), y_n).$$

- Здесь  $\delta_n$  – является обучаемым параметром, которые и отвечает за небольшой шум входных данных.



Figure: Слева картинка, которую AlexNet классифицирует правильно, по центру – небольшой шум, который мы вносим, справа – картинка, которую распознают неправильно. Картинка из статьи.

# GANs

- GAN представляет собой две модели генератор  $G$  и дискриминатор  $D$ .
- $D$  принимает на вход элемент  $x$  и определяет, является ли этот элемент реальным (из выборки данных) или искусственно созданным генератором.
- На вход генератор подается некоторый случайный вектор  $z$ , по которому генератор строит "фейковый" экземпляр, похожий на реальную выборку.
- Формально задачу GAN формулируют в виде седловой:

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))].$$

# Основные предположения

## Липшицевость

Оператор  $F$  называется Липшицев с константой  $L$ , если

$$\|F(z_1) - F(z_2)\| \leq L\|z_1 - z_2\|, \quad \forall z_1, z_2 \in \mathcal{Z}.$$

Аналогия: Липшецевость градиента.

## Сильная монотонность

Оператор  $F$  называется сильно монотонным с константой  $\mu$ , если

$$\langle F(z_1) - F(z_2), z_1 - z_2 \rangle \geq \mu\|z_1 - z_2\|^2, \quad \forall z_1, z_2 \in \mathcal{Z}.$$

Аналогия: сильная выпуклость.

Для седел: писать сильную-выпуклость/выпуклость по  $x$  и сильную-вогнутость/вогнутость по  $y$ .

# Основные предположения

## Липшицевость

Оператор  $F$  называется Липшицев с константой  $L$ , если

$$\|F(z_1) - F(z_2)\| \leq L\|z_1 - z_2\|, \quad \forall z_1, z_2 \in \mathcal{Z}.$$

Аналогия: Липшецевость градиента.

## Сильная монотонность

Оператор  $F$  называется сильно монотонным с константой  $\mu$ , если

$$\langle F(z_1) - F(z_2), z_1 - z_2 \rangle \geq \mu\|z_1 - z_2\|^2, \quad \forall z_1, z_2 \in \mathcal{Z}.$$

Аналогия: сильная выпуклость.

Для седел: писать сильную-выпуклость/выпуклость по  $x$  и сильную-вогнутость/вогнутость по  $y$ .

# Базовые методы: а ля градиентный спуск

- Классический спуск(-подъем):

$$z^{k+1} = \text{proj}_Z(z^k - \gamma F(z^k)).$$

# Базовые методы: а ля градиентный спуск

- В сильно монотонном случае:

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &= \|\text{proj}_Z(z^k - \gamma F(z^k)) - \text{proj}_Z(z^*)\|^2 \\ &\leq \|z^k - \gamma F(z^k) - z^*\|^2 \\ &= \|z^k - z^*\|^2 - 2\gamma \langle z^k - z^*, F(z^k) \rangle + \gamma^2 \|F(z^k)\|^2 \\ &\leq \|z^k - z^*\|^2 - 2\gamma \langle z^k - z^*, F(z^k) \rangle + 2\gamma^2 \|F(z^k) - F(z^*)\|^2 \\ &\quad + 2\gamma^2 \|F(z^*)\|^2 \\ &\leq \|z^k - z^*\|^2 - 2\gamma \langle z^k - z^*, F(z^k) \rangle + 2\gamma^2 L^2 \|z^k - z^*\|^2 \\ &\quad + 2\gamma^2 \|F(z^*)\|^2 \\ &\leq \|z^k - z^*\|^2 - 2\gamma \langle z^k - z^*, F(z^k) - F(z^*) \rangle \\ &\quad + 2\gamma^2 L^2 \|z^k - z^*\|^2 + 2\gamma^2 \|F(z^*)\|^2 \\ &\leq \|z^k - z^*\|^2 - 2\gamma \mu \|z^k - z^*\|^2 \\ &\quad + 2\gamma^2 L^2 \|z^k - z^*\|^2 + 2\gamma^2 \|F(z^*)\|^2.\end{aligned}$$

## Базовые методы: а ля градиентный спуск

- Выбор  $\gamma \leq \frac{\mu}{2L^2}$ :

$$\|z^{k+1} - z^*\|^2 \leq (1 - \mu\gamma)\|z^k - z^*\|^2 + \gamma^2\|F(z^*)\|^2.$$

- Линейная (но медленная) сходимость в случае  $F(z^*) = 0$ . Сложность:

$$O\left(\frac{L^2}{\mu^2} \log \frac{1}{\varepsilon}\right).$$

## Базовые методы: а ля градиентный спуск

- Выбор  $\gamma \leq \frac{\mu}{2L^2}$ :

$$\|z^{k+1} - z^*\|^2 \leq (1 - \mu\gamma)\|z^k - z^*\|^2 + \gamma^2\|F(z^*)\|^2.$$

- Линейная (но медленная) сходимость в случае  $F(z^*) = 0$ . Сложность:

$$O\left(\frac{L^2}{\mu^2} \log \frac{1}{\varepsilon}\right).$$

# Базовые методы: а ля градиентный спуск

- Классический спуск(-подъем):

$$z^{k+1} = \text{proj}_Z(z^k - \gamma F(z^k)).$$

# Базовые методы: а ля градиентный спуск

- Билинейная задача:

$$\min_{x \in \mathbb{R}} \max_{y \in \mathbb{R}} xy$$

Где у нее решение?

- Решение:  $x^* = 0$ ,  $y^* = 0$  (из условия оптимальности)
- Тогда

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &= (x^{k+1} - x^*)^2 + (y^{k+1} - y^*)^2 \\ &= (x^k - \gamma y^k)^2 + (y^k + \gamma x^k)^2 \\ &= (1 + \gamma^2) [(x^k - x^*)^2 + (y^k - y^*)^2] \\ &= (1 + \gamma^2) \|z^{k+1} - z^*\|^2. \end{aligned}$$

# Базовые методы: а ля градиентный спуск

- Билинейная задача:

$$\min_{x \in \mathbb{R}} \max_{y \in \mathbb{R}} xy$$

Где у нее решение?

- Решение:  $x^* = 0$ ,  $y^* = 0$  (из условия оптимальности)
- Тогда

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &= (x^{k+1} - x^*)^2 + (y^{k+1} - y^*)^2 \\ &= (x^k - \gamma y^k)^2 + (y^k + \gamma x^k)^2 \\ &= (1 + \gamma^2) [(x^k - x^*)^2 + (y^k - y^*)^2] \\ &= (1 + \gamma^2) \|z^{k+1} - z^*\|^2. \end{aligned}$$

# Базовые методы: а ля градиентный спуск

- Билинейная задача:

$$\min_{x \in \mathbb{R}} \max_{y \in \mathbb{R}} xy$$

Где у нее решение?

- Решение:  $x^* = 0$ ,  $y^* = 0$  (из условия оптимальности)
- Тогда

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &= (x^{k+1} - x^*)^2 + (y^{k+1} - y^*)^2 \\ &= (x^k - \gamma y^k)^2 + (y^k + \gamma x^k)^2 \\ &= (1 + \gamma^2) [(x^k - x^*)^2 + (y^k - y^*)^2] \\ &= (1 + \gamma^2) \|z^{k+1} - z^*\|^2. \end{aligned}$$

# Базовые методы: а ля градиентный спуск

- Классический спуск(-подъем):

$$z^{k+1} = \text{proj}_Z(z^k - \gamma_k F(z^k)).$$

- Спуск(-подъем) с дополнительным шагом (Extra Step):

$$\begin{aligned} z^{k+1/2} &= \text{proj}_Z(z^k - \gamma_k F(z^k)), \\ z^{k+1} &= \text{proj}_Z(z^k - \gamma_k F(z^{k+1/2})). \end{aligned}$$

[Korpelevich, 1976, Nemirovski, 2004]

# Сходимость: лемма спуска

## Лемма спуска для Extra Step

Для одной итерации Extra Step метода справедливо следующее равенство (для любого  $u \in \mathcal{Z}$ ):

$$\begin{aligned}\|z^{k+1} - u\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}), z^{k+1/2} - u \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2.\end{aligned}$$

Докажем:

$$\begin{aligned}\|z^{k+1} - u\|^2 &= \|z^{k+1} - z^k + z^k - u\|^2 \\ &= \|z^k - u\|^2 + 2\langle z^{k+1} - z^k, z^k - u \rangle + \|z^{k+1} - z^k\|^2 \\ &= \|z^k - u\|^2 + 2\langle z^{k+1} - z^k, z^{k+1} - u \rangle \\ &\quad - 2\langle z^{k+1} - z^k, z^{k+1} - z^k \rangle + \|z^{k+1} - z^k\|^2 \\ &= \|z^k - u\|^2 + 2\langle z^{k+1} - z^k, z^{k+1} - u \rangle - \|z^{k+1} - z^k\|^2 \\ &= \|z^k - u\|^2 - 2\gamma \langle F(z^{k+1/2}), z^{k+1} - u \rangle - \|z^{k+1} - z^k\|^2.\end{aligned}$$

# Сходимость: лемма спуска

## Лемма спуска для Extra Step

Для одной итерации Extra Step метода справедливо следующее равенство (для любого  $u \in \mathcal{Z}$ ):

$$\begin{aligned}\|z^{k+1} - u\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}), z^{k+1/2} - u \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2.\end{aligned}$$

Докажем:

$$\begin{aligned}\|z^{k+1} - u\|^2 &= \|z^{k+1} - z^k + z^k - u\|^2 \\ &= \|z^k - u\|^2 + 2\langle z^{k+1} - z^k, z^k - u \rangle + \|z^{k+1} - z^k\|^2 \\ &= \|z^k - u\|^2 + 2\langle z^{k+1} - z^k, z^{k+1} - u \rangle \\ &\quad - 2\langle z^{k+1} - z^k, z^{k+1} - z^k \rangle + \|z^{k+1} - z^k\|^2 \\ &= \|z^k - u\|^2 + 2\langle z^{k+1} - z^k, z^{k+1} - u \rangle - \|z^{k+1} - z^k\|^2 \\ &= \|z^k - u\|^2 - 2\gamma \langle F(z^{k+1/2}), z^{k+1} - u \rangle - \|z^{k+1} - z^k\|^2.\end{aligned}$$

# Сходимость: лемма спуска

Аналогично:

$$\begin{aligned}\|z^{k+1/2} - z^{k+1}\|^2 &= \|z^{k+1/2} - z^k + z^k - z^{k+1}\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^k - z^{k+1} \rangle + \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^{k+1} \rangle \\ &\quad - 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^k \rangle + \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^{k+1} \rangle - \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 - 2\gamma\langle F(z^k), z^{k+1/2} - z^{k+1} \rangle - \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сложим два полученных равенства:

$$\begin{aligned}\|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\langle F(z^{k+1/2}), z^{k+1} - u \rangle - 2\gamma\langle F(z^k), z^{k+1/2} - z^{k+1} \rangle.\end{aligned}$$

Далее немного реорганизуем правую часть:

$$\begin{aligned}\|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\langle F(z^{k+1/2}), z^{k+1/2} - u \rangle \\ &\quad + 2\gamma\langle F(z^{k+1/2}) - F(z^k), z^{k+1/2} - z^{k+1} \rangle.\end{aligned}$$

# Сходимость: лемма спуска

Аналогично:

$$\begin{aligned}\|z^{k+1/2} - z^{k+1}\|^2 &= \|z^{k+1/2} - z^k + z^k - z^{k+1}\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^k - z^{k+1} \rangle + \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^{k+1} \rangle \\ &\quad - 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^k \rangle + \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^{k+1} \rangle - \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 - 2\gamma\langle F(z^k), z^{k+1/2} - z^{k+1} \rangle - \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сложим два полученных равенства:

$$\begin{aligned}\|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\langle F(z^{k+1/2}), z^{k+1} - u \rangle - 2\gamma\langle F(z^k), z^{k+1/2} - z^{k+1} \rangle.\end{aligned}$$

Далее немного реорганизуем правую часть:

$$\begin{aligned}\|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\langle F(z^{k+1/2}), z^{k+1/2} - u \rangle \\ &\quad + 2\gamma\langle F(z^{k+1/2}) - F(z^k), z^{k+1/2} - z^{k+1} \rangle.\end{aligned}$$

# Сходимость: лемма спуска

Аналогично:

$$\begin{aligned}\|z^{k+1/2} - z^{k+1}\|^2 &= \|z^{k+1/2} - z^k + z^k - z^{k+1}\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^k - z^{k+1} \rangle + \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^{k+1} \rangle \\ &\quad - 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^k \rangle + \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 + 2\langle z^{k+1/2} - z^k, z^{k+1/2} - z^{k+1} \rangle - \|z^{k+1/2} - z^k\|^2 \\ &= \|z^k - z^{k+1}\|^2 - 2\gamma\langle F(z^k), z^{k+1/2} - z^{k+1} \rangle - \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сложим два полученных равенства:

$$\begin{aligned}\|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\langle F(z^{k+1/2}), z^{k+1} - u \rangle - 2\gamma\langle F(z^k), z^{k+1/2} - z^{k+1} \rangle.\end{aligned}$$

Далее немного реорганизуем правую часть:

$$\begin{aligned}\|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &= \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\langle F(z^{k+1/2}), z^{k+1/2} - u \rangle \\ &\quad + 2\gamma\langle F(z^{k+1/2}) - F(z^k), z^{k+1/2} - z^{k+1} \rangle.\end{aligned}$$

# Сходимость: лемма спуска

Воспользуемся  $2ab \leq a^2 + b^2$ :

$$\begin{aligned} \|z^{k+1} - u\|^2 + \|z^{k+1/2} - z^{k+1}\|^2 &\leq \|z^k - u\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}), z^{k+1/2} - u \rangle \\ &\quad + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2 + \|z^{k+1/2} - z^{k+1}\|^2, \end{aligned}$$

что и доказывает лемму.

Произвольное  $u$  в данной лемме нужно для монотонных ВН (выпукло-вогнутых седловых задач), в сильно-монотонном случае достаточно взять  $u = z^*$ .

# Сходимость: сильно-монотонный случай

## Теорема для Extra Step

В сильно-монотонном случае для Extra Step метода с  $\gamma \leq \frac{1}{4L}$  справедлива следующая оценка сходимости ( $z^K$  – последняя точка алгоритма,  $z^0$  – начальная):

$$\|z^K - z^*\|^2 \leq (1 - \gamma\mu)^K \|z^0 - z^*\|^2.$$

Подставим в лемму  $u = z^*$ :

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}), z^{k+1/2} - z^* \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2. \end{aligned}$$

Воспользуемся свойством решения:  $\langle F(z^*), z^{k+1/2} - z^* \rangle \geq 0$ ,

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}) - F(z^*), z^{k+1/2} - z^* \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2. \end{aligned}$$

# Сходимость: сильно-монотонный случай

## Теорема для Extra Step

В сильно-монотонном случае для Extra Step метода с  $\gamma \leq \frac{1}{4L}$  справедлива следующая оценка сходимости ( $z^K$  – последняя точка алгоритма,  $z^0$  – начальная):

$$\|z^K - z^*\|^2 \leq (1 - \gamma\mu)^K \|z^0 - z^*\|^2.$$

Подставим в лемму  $u = z^*$ :

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}), z^{k+1/2} - z^* \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2. \end{aligned}$$

Воспользуемся свойством решения:  $\langle F(z^*), z^{k+1/2} - z^* \rangle \geq 0$ ,

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}) - F(z^*), z^{k+1/2} - z^* \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2. \end{aligned}$$

# Сходимость: сильно-монотонный случай

## Теорема для Extra Step

В сильно-монотонном случае для Extra Step метода с  $\gamma \leq \frac{1}{4L}$  справедлива следующая оценка сходимости ( $z^K$  – последняя точка алгоритма,  $z^0$  – начальная):

$$\|z^K - z^*\|^2 \leq (1 - \gamma\mu)^K \|z^0 - z^*\|^2.$$

Подставим в лемму  $u = z^*$ :

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}), z^{k+1/2} - z^* \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2. \end{aligned}$$

Воспользуемся свойством решения:  $\langle F(z^*), z^{k+1/2} - z^* \rangle \geq 0$ ,

$$\begin{aligned} \|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma \langle F(z^{k+1/2}) - F(z^*), z^{k+1/2} - z^* \rangle + \gamma^2 \|F(z^{k+1/2}) - F(z^k)\|^2. \end{aligned}$$

# Сходимость: сильно-монотонный случай

Далее применяем сильную монотонность и Липшецевость:

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\mu\|z^{k+1/2} - z^*\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Используем следующее неравенство:  $-2\|z^{k+1/2} - z^*\|^2 \leq -\|z^k - z^*\|^2 + 2\|z^{k+1/2} - z^k\|^2$   
(модификация  $\|a + b\|^2 \leq 2\|a\|^2 + 2\|b\|^2$ ):

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - \gamma\mu\|z^k - z^*\|^2 + 2\gamma\mu\|z^{k+1/2} - z^k\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сгруппируем:

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2 - (1 - 2\gamma\mu + \gamma^2 L^2)\|z^{k+1/2} - z^k\|^2.$$

С  $\gamma \leq \frac{1}{4L}$  имеем

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2.$$

Откуда и следует требуемое утверждение.

# Сходимость: сильно-монотонный случай

Далее применяем сильную монотонность и Липшецевость:

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\mu\|z^{k+1/2} - z^*\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Используем следующее неравенство:  $-2\|z^{k+1/2} - z^*\|^2 \leq -\|z^k - z^*\|^2 + 2\|z^{k+1/2} - z^k\|^2$   
(модификация  $\|a + b\|^2 \leq 2\|a\|^2 + 2\|b\|^2$ ):

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - \gamma\mu\|z^k - z^*\|^2 + 2\gamma\mu\|z^{k+1/2} - z^k\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сгруппируем:

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2 - (1 - 2\gamma\mu + \gamma^2 L^2)\|z^{k+1/2} - z^k\|^2.$$

С  $\gamma \leq \frac{1}{4L}$  имеем

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2.$$

Откуда и следует требуемое утверждение.

# Сходимость: сильно-монотонный случай

Далее применяем сильную монотонность и Липшецевость:

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\mu\|z^{k+1/2} - z^*\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Используем следующее неравенство:  $-2\|z^{k+1/2} - z^*\|^2 \leq -\|z^k - z^*\|^2 + 2\|z^{k+1/2} - z^k\|^2$   
(модификация  $\|a + b\|^2 \leq 2\|a\|^2 + 2\|b\|^2$ ):

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - \gamma\mu\|z^k - z^*\|^2 + 2\gamma\mu\|z^{k+1/2} - z^k\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сгруппируем:

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2 - (1 - 2\gamma\mu + \gamma^2 L^2)\|z^{k+1/2} - z^k\|^2.$$

С  $\gamma \leq \frac{1}{4L}$  имеем

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2.$$

Откуда и следует требуемое утверждение.

# Сходимость: сильно-монотонный случай

Далее применяем сильную монотонность и Липшецевость:

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - 2\gamma\mu\|z^{k+1/2} - z^*\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Используем следующее неравенство:  $-2\|z^{k+1/2} - z^*\|^2 \leq -\|z^k - z^*\|^2 + 2\|z^{k+1/2} - z^k\|^2$  (модификация  $\|a + b\|^2 \leq 2\|a\|^2 + 2\|b\|^2$ ):

$$\begin{aligned}\|z^{k+1} - z^*\|^2 &\leq \|z^k - z^*\|^2 - \|z^{k+1/2} - z^k\|^2 \\ &\quad - \gamma\mu\|z^k - z^*\|^2 + 2\gamma\mu\|z^{k+1/2} - z^k\|^2 + \gamma^2 L^2 \|z^{k+1/2} - z^k\|^2.\end{aligned}$$

Сгруппируем:

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2 - (1 - 2\gamma\mu + \gamma^2 L^2)\|z^{k+1/2} - z^k\|^2.$$

С  $\gamma \leq \frac{1}{4L}$  имеем

$$\|z^{k+1} - z^*\|^2 \leq (1 - \gamma\mu)\|z^k - z^*\|^2.$$

Откуда и следует требуемое утверждение.

# Сходимости: сравнение с выпуклой минимизацией

Суммируем результаты в виде таблицы:

Случай	Верхняя оценка ВН - Extra Step	Нижняя оценка (лучше не получится)	Верхняя оценка Оптимизация - Нестеров
Сильно-вып.	$\mathcal{O}\left(\left(1 - \frac{\mu}{L}\right)^K \ z^0 - z^*\ ^2\right)$	$\Omega\left(\left(1 - \frac{8\mu}{L}\right)^K \ z^0 - z^*\ ^2\right)$	$\mathcal{O}\left(\left(1 - \sqrt{\frac{\mu}{L}}\right)^K \ z^0 - z^*\ ^2\right)$
Выпуклый	$\mathcal{O}\left(\frac{LD_Z^2}{K}\right)$	$\Omega\left(\frac{LD_Z^2}{K}\right)$	$\mathcal{O}\left(\frac{LD_Z^2}{K^2}\right)$

- Extra Step – оптимальный метод для седел и ВН.
- Седла нельзя ускорить (если не углубляться в специфику константа  $L, \mu$ ).
- Напомню, для выпуклой оптимизации оптимальным методом является, например, ускоренный метод Нестерова. В том числе из-за этого ее рассматривают отдельно от ВН.

# Метод с дополнительным шагом

Плюсы:

- Взгляд в "будущие": делает шаг по "градиенту" в "будущей" точке.
- Оптимальный теоретический анализ.
- Показывает лучшие результаты на практике (по количеству итераций).

Минусы:

- Два вызова "градиента" за итерацию.
- Часто уступает на практике обычному спуску по количеству вызовов "градиента".

# Метод с дополнительным шагом

Плюсы:

- Взгляд в "будущие": делает шаг по "градиенту" в "будущей" точке.
- Оптимальный теоретический анализ.
- Показывает лучшие результаты на практике (по количеству итераций).

Минусы:

- Два вызова "градиента" за итерацию.
- Часто уступает на практике обычному спуску по количеству вызовов "градиента".

# Боремся с минусом

Рассмотрим следующие модификации:

- Past Extra Step Method

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma F(z^{k-1/2})), \\z^{k+1} &= \text{proj}_Z(z^k - \gamma F(z^{k+1/2})).\end{aligned}$$

- Optimistic Extra Step Method

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma F(z^{k-1/2})), \\z^{k+1} &= z^{k+1/2} - \gamma F(z^{k+1/2}) + \gamma F(z^{k-1/2}).\end{aligned}$$

- Reflected Extra Step Method

$$\begin{aligned}z^{k+1/2} &= 2 \cdot z^k - z^{k-1}, \\z^{k+1} &= \text{proj}_Z(z^k - \gamma F(z^{k+1/2})).\end{aligned}$$

[Popov, 1980, Hsieh et al., 2019]

# Немного об ускорениях

- Еще раз: ВН и седла в теории не ускоряются!
- Рассмотрим все же моментные методы:
$$z^{k+1} = z^k - \gamma_k F(z^k) + \beta(z^k - z^{k-1})$$
- Но есть интуиция, что для седел лучше использовать отрицательные моменты ( $\beta < 0$ ):

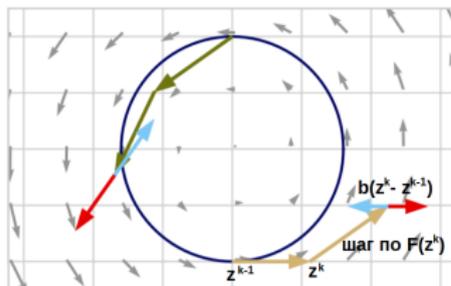


Figure: Рассматривается вихревое, спиралевидное поле, равное 0 в центре – решение. Коричневым показана траектория метода, красным и синим способы выбора момента: красный – положительным, синий – отрицательным. Видно, что отрицательный лучше - он тянет в центр к решению. Зеленая траектория – альтернативный подход к выбору момента. Картинка отсюда.

# Немного об ускорениях

- Еще раз: ВН и седла в теории не ускоряются!
- Рассмотрим все же моментные методы:
$$z^{k+1} = z^k - \gamma_k F(z^k) + \beta(z^k - z^{k-1})$$
- Но есть интуиция, что для седел лучше использовать отрицательные моменты ( $\beta < 0$ ):

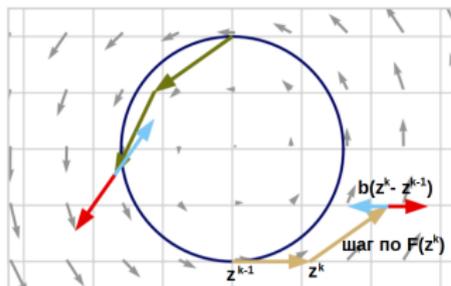
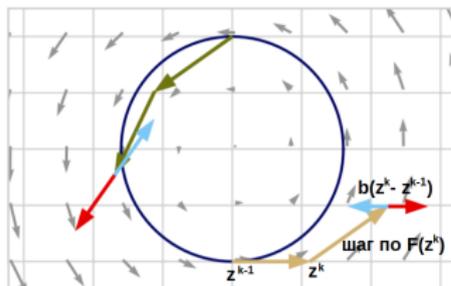


Figure: Рассматривается вихревое, спиралевидное поле, равное 0 в центре – решение. Коричневым показана траектория метода, красным и синим способы выбора момента: красный – положительным, синий – отрицательным. Видно, что отрицательный лучше - он тянет в центр к решению. Зеленая траектория – альтернативный подход к выбору момента. Картинка отсюда.

# Немного об ускорениях

- Еще раз: ВН и седла в теории не ускоряются!
- Рассмотрим все же моментные методы:
$$z^{k+1} = z^k - \gamma_k F(z^k) + \beta(z^k - z^{k-1})$$
- Но есть интуиция, что для седел лучше использовать отрицательные моменты ( $\beta < 0$ ):



**Figure:** Рассматривается вихревое, спиралевидное поле, равное 0 в центре – решение. Коричневым показана траектория метода, красным и синим способы выбора момента: красный – положительным, синий – отрицательным. Видно, что отрицательный лучше - он тянет в центр к решению. Зеленая траектория – альтернативный подход к выбору момента. Картинка отсюда.

# Стохастические методы

Решаются те же самые проблемы ВН или седловой точки: 1) Найти  $z^* \in \mathcal{Z}$  такую, что  $\langle F(z^*), z - z^* \rangle \geq 0, \forall z \in \mathcal{Z}$  или 2)  $\min_{x \in \mathcal{X}} \max_{y \in \mathcal{Y}} g(x, y)$ .  
Но теперь мы не имеем доступа к точным значениям  $F(z)$  или  $g(x, y)$ .

Выделим, две популярные стохастические постановки:

- Мы имеем доступ к некоторой стохастической реализации  $F(z, \xi)$  или  $g(x, y, \xi)$ .  $\xi$  может отвечать за некоторый шум, например:  $F(z, \xi) = F(z) + \xi$ ; или  $\xi$  – это номер батча, который выбирается случайно.
- Монте-Карло постановка:

$$F(z) = \frac{1}{M} \sum_{m=1}^M F_m(z) \text{ или } g(x, y) = \frac{1}{M} \sum_{m=1}^M g_m(x, y).$$

Интерпретация: батч, выбирается случайный на каждой итерации.

# Стохастические методы

Решаются те же самые проблемы ВН или седловой точки: 1) Найти  $z^* \in \mathcal{Z}$  такую, что  $\langle F(z^*), z - z^* \rangle \geq 0, \forall z \in \mathcal{Z}$  или 2)  $\min_{x \in \mathcal{X}} \max_{y \in \mathcal{Y}} g(x, y)$ .

Но теперь мы не имеем доступа к точным значениям  $F(z)$  или  $g(x, y)$ .

Выделим, две популярные стохастические постановки:

- Мы имеем доступ к некоторой стохастической реализации  $F(z, \xi)$  или  $g(x, y, \xi)$ .  $\xi$  может отвечать за некоторый шум, например:  $F(z, \xi) = F(z) + \xi$ ; или  $\xi$  – это номер батча, который выбирается случайно.
- Монте-Карло постановка:

$$F(z) = \frac{1}{M} \sum_{m=1}^M F_m(z) \text{ или } g(x, y) = \frac{1}{M} \sum_{m=1}^M g_m(x, y).$$

Интерпретация: батч, выбирается случайный на каждой итерации.

# Стохастические методы

Решаются те же самые проблемы ВН или седловой точки: 1) Найти  $z^* \in \mathcal{Z}$  такую, что  $\langle F(z^*), z - z^* \rangle \geq 0, \forall z \in \mathcal{Z}$  или 2)  $\min_{x \in \mathcal{X}} \max_{y \in \mathcal{Y}} g(x, y)$ .

Но теперь мы не имеем доступа к точным значениям  $F(z)$  или  $g(x, y)$ .

Выделим, две популярные стохастические постановки:

- Мы имеем доступ к некоторой стохастической реализации  $F(z, \xi)$  или  $g(x, y, \xi)$ .  $\xi$  может отвечать за некоторый шум, например:  $F(z, \xi) = F(z) + \xi$ ; или  $\xi$  – это номер батча, который выбирается случайно.
- Монте-Карло постановка:

$$F(z) = \frac{1}{M} \sum_{m=1}^M F_m(z) \text{ или } g(x, y) = \frac{1}{M} \sum_{m=1}^M g_m(x, y).$$

Интерпретация: батч, выбирается случайный на каждой итерации.

## Базовый Метод: все тот же

- Стохастический спуск(-подъем) с дополнительным шагом (Extra Step):

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma_k F(z^k, \xi^k)), \\z^{k+1} &= \text{proj}_Z(z^k - \gamma_k F(z^{k+1/2}, \xi^{k+1/2})).\end{aligned}$$

- Предположения:  $\mathbb{E}_\xi F(z, \xi) = F(z)$ ,  $\mathbb{E}_\xi \|F(z, \xi) - F(z)\|^2 \leq \sigma^2$ .
- Сходимость: при постоянном шаге к окрестности решения.

[Juditsky et al., 2011]

# Метод: сходимость

- Оценки сходимости:

Случай	Верхняя оценка ВН - Extra Step	Верхняя оценка Оптимизация - Нестеров
Сильно-вып.	$\mathcal{O}\left(\left(1 - \frac{\mu}{L}\right)^K \ z^0 - z^*\ ^2 + \frac{\sigma^2}{\mu K}\right)$	$\mathcal{O}\left(\left(1 - \sqrt{\frac{\mu}{L}}\right)^K \ z^0 - z^*\ ^2 + \frac{\sigma^2}{\mu K}\right)$
Выпуклый	$\mathcal{O}\left(\frac{LD_Z^2}{K} + \frac{\sigma D_Z}{\sqrt{K}}\right)$	$\mathcal{O}\left(\frac{LD_Z^2}{K^2} + \frac{\sigma D_Z}{\sqrt{K}}\right)$

# Метод: сходимость

Билинейная задача:

$$\min_{x,y \in [-1;1]^n} \max (x^T A y + b^T x + c^T y),$$

Концепция:  $F(z, \xi) = F(z) + \xi$ , где  $\mathbb{E}\xi = 0$ ,  $\mathbb{E}\|\xi\|^2 = \sigma^2$ . Подбирается шаг, обеспечивающий наилучшую сходимость.

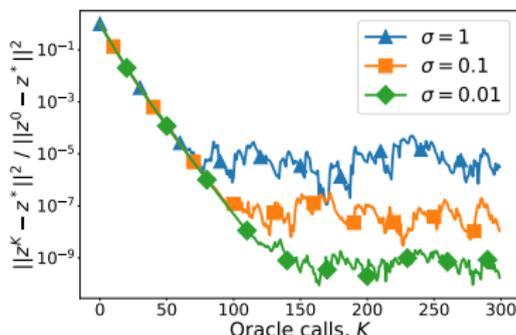


Figure: Сходимость стохастического Extra Step метода с разным уровнем шума  $\sigma$ .

# Модификации: Revisiting Extra Step

- Идея использовать ту же случайность  $\xi^k$  на обоих шагах:

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma_k F(z^k, \xi^k)), \\z^{k+1} &= \text{proj}_Z(z^k - \gamma_k F(z^{k+1/2}, \xi^k)).\end{aligned}$$

- В Монте-Карло постановке:

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma_k F_{\pi_k}(z^k)), \\z^{k+1} &= \text{proj}_Z(z^k - \gamma_k F_{\pi_k}(z^{k+1/2})).\end{aligned}$$

[Mishchenko et al., 2020, Gorbunov et al., 2021]

## Модификации: Revisiting Extra Step

- Идея использовать ту же случайность  $\xi^k$  на обоих шагах:

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma_k F(z^k, \xi^k)), \\z^{k+1} &= \text{proj}_Z(z^k - \gamma_k F(z^{k+1/2}, \xi^k)).\end{aligned}$$

- В Монте-Карло постановке:

$$\begin{aligned}z^{k+1/2} &= \text{proj}_Z(z^k - \gamma_k F_{\pi_k}(z^k)), \\z^{k+1} &= \text{proj}_Z(z^k - \gamma_k F_{\pi_k}(z^{k+1/2})).\end{aligned}$$

[Mishchenko et al., 2020, Gorbunov et al., 2021]

# Revisiting Extra Step: сходимость

Билинейная задача:

$$\min_{x,y \in [-1;1]^n} \max (x^T Ay),$$

Концепция №1:  $F(z, \xi) = F(z) + \xi$ , где  $\mathbb{E}\xi = 0$ ,  $\mathbb{E}\|\xi\|^2 = \sigma^2$ .

Концепция №2 (Монте-Карло):  $A = \frac{1}{M} \sum_{m=1}^M A_m$ . Выбирается случайная матрица  $A_m$ .

Подбирается шаг, обеспечивающий наилучшую сходимость. Более того, в этом эксперименте он оказался одинаковым.

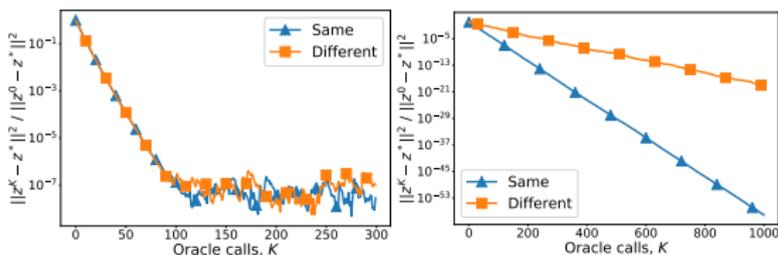


Figure: Сравнение обычного Extra Step с разными  $\xi$  с Revisiting Extra Step: левый график – для концепции  $F(z, \xi) = F(z) + \xi$ , правый график – для Монте-Карло

# Variance Reduction: 5 подходов

- Стандартный:

$$z^{k+1} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

- Extra Step:

$$z^{k+1/2} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

$$z^{k+1} = \text{proj}_Z(z^k - \gamma(F_{\pi_{k+1/2}}(z^k) - F_{\pi_{k+1/2}}(w^k) + F(w^k))),$$

- Extra Step Revisiting:

$$z^{k+1/2} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

$$z^{k+1} = z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k)).$$

# Variance Reduction: 5 подходов

- Стандартный:

$$z^{k+1} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

- Extra Step:

$$z^{k+1/2} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

$$z^{k+1} = \text{proj}_Z(z^k - \gamma(F_{\pi_{k+1/2}}(z^k) - F_{\pi_{k+1/2}}(w^k) + F(w^k))),$$

- Extra Step Revisiting:

$$z^{k+1/2} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

$$z^{k+1} = z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k)).$$

# Variance Reduction: 5 подходов

- Стандартный:

$$z^{k+1} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

- Extra Step:

$$z^{k+1/2} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

$$z^{k+1} = \text{proj}_Z(z^k - \gamma(F_{\pi_{k+1/2}}(z^k) - F_{\pi_{k+1/2}}(w^k) + F(w^k))),$$

- Extra Step Revisiting:

$$z^{k+1/2} = \text{proj}_Z(z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k))),$$

$$z^{k+1} = z^k - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k)).$$

# Variance Reduction: 5 подходов

- Но правильные и наилучшие оценки дает:

$$z^{k+1/2} = \text{proj}_Z(z^k - \alpha(z^k - w^k) - \gamma F(w^k)),$$

$$z^{k+1} = \text{proj}_Z(z^k - \alpha(z^k - w^k) - \gamma(F_{\pi_k}(z^k) - F_{\pi_k}(w^k) + F(w^k)))$$

$$w^{k+1} = \begin{cases} z^{k+1} & \text{with small probability } p, \\ w^k & \text{with probability } 1 - p. \end{cases}$$

- Негативный моментум является ключевым в теоретическом анализе.

[Alacaoglu and Malitsky, 2021]

# Variance Reduction: 5 подходов

- А также:

$$\Delta^k = \frac{1}{b} \sum_{j \in S^k} (F_{\pi_j}(z^k) - F_{\pi_j}(w^{k-1}) + \eta(F_{\pi_j}(z^k) - F_{\pi_j}(z^{k-1}))) + F(w^{k-1}),$$

$$z^{k+1} = \text{proj}_Z(z^k - \alpha(z^k - w^k) - \gamma\Delta^k)$$

$$w^{k+1} = \begin{cases} z^{k+1} & \text{with small probability } p, \\ w^k & \text{with probability } 1 - p. \end{cases}$$

[Kovalev et al., 2022]

**Table:** Summary complexities for finding an  $\varepsilon$ -solution for strongly monotone stochastic (finite-sum) variational inequality.

Reference	Complexity	Weaknesses
[Palaniappan and Bach, 2016]	$\mathcal{O}\left(n + \sqrt{bn} \frac{L}{\mu} \log^2 \frac{1}{\varepsilon}\right)$	envelope acceleration batching
[Chavdarova et al., 2019]	$\mathcal{O}\left(n + b \frac{L^2}{\mu^2} \log \frac{1}{\varepsilon}\right)$	bad complexity batching
[Carmon et al., 2019]	$\mathcal{O}\left(n + \sqrt{bn} \frac{L}{\mu} \log \frac{1}{\varepsilon}\right)$	for games only batching
[Yang et al., 2020]	$\mathcal{O}\left(b^{\frac{1}{3}} n^{\frac{2}{3}} \frac{L^3}{\mu^3} \log \frac{1}{\varepsilon}\right)$	bad complexity batching
[Alacaoglu and Malitsky, 2021]	$\mathcal{O}\left(n + \sqrt{bn} \frac{L}{\mu} \log \frac{1}{\varepsilon}\right)$	batching
[Alacaoglu et al., 2021]	$\mathcal{O}\left(n + n \frac{L}{\mu} \log \frac{1}{\varepsilon}\right)$	bad rates
[Tominin et al., 2021]	$\mathcal{O}\left(n + \sqrt{bn} \frac{L}{\mu} \log^2 \frac{1}{\varepsilon}\right)$	envelope acceleration batching
[Kovalev et al., 2022]	$\mathcal{O}\left(n + \sqrt{n} \frac{L}{\mu} \log \frac{1}{\varepsilon}\right)$	
Нижняя оценка	$\Omega\left(n + \sqrt{n} \frac{L}{\mu} \log \frac{1}{\varepsilon}\right)$	

# Распределенные ВН с сжатием через VR

- Распределенная задача:

$$F(z) = \frac{1}{M} \sum_{m=1}^M F_m(z),$$

где  $F_m$  распределены по вычислительным устройствам.

- Коммуникации стоят значительно дороже!
- Для удешевления коммуникаций можно сжимать информацию:

$$EQ(z) = z, \quad E\|Q(z)\|^2 \leq q\|z\|^2.$$

# Распределенные ВН с сжатием через VR

- Распределенная задача:

$$F(z) = \frac{1}{M} \sum_{m=1}^M F_m(z),$$

где  $F_m$  распределены по вычислительным устройствам.

- Коммуникации стоят значительно дороже!
- Для удешевления коммуникаций можно сжимать информацию:

$$EQ(z) = z, \quad E\|Q(z)\|^2 \leq q\|z\|^2.$$

# Распределенные ВН с сжатием через VR

- Распределенная задача:

$$F(z) = \frac{1}{M} \sum_{m=1}^M F_m(z),$$

где  $F_m$  распределены по вычислительным устройствам.

- Коммуникации стоят значительно дороже!
- Для удешевления коммуникаций можно сжимать информацию:

$$EQ(z) = z, \quad E\|Q(z)\|^2 \leq q\|z\|^2.$$

# Распределенные ВН с сжатием через VR

- Локально считаем

$$z^{k+1/2} = z^k - \alpha(z^k - w^k) - \gamma F(w^k)$$

- Посылаем на сервер

$$g_m^k = Q_m^{\text{dev}}(F_m(z^{k+1/2}) - F_m(w^k))$$

- Получаем усредненный ответ

$$g^k = Q^{\text{serv}} \left[ \frac{1}{M} \sum_{m=1}^M g_m^k \right]$$

- Локально обновляемся

$$z^{k+1} = z^{k+1/2} - \gamma g^k$$
$$w^{k+1} = \begin{cases} z^{k+1} & \text{with small probability } p, \\ w^k & \text{with probability } 1 - p. \end{cases}$$

[Beznosikov et al., 2021]



Alacaoglu, A. and Malitsky, Y. (2021).  
Stochastic variance reduction for variational inequality methods.  
[arXiv preprint arXiv:2102.08352](https://arxiv.org/abs/2102.08352).



Alacaoglu, A., Malitsky, Y., and Cevher, V. (2021).  
Forward-reflected-backward method with variance reduction.  
[Computational Optimization and Applications](#), 80.



Beznosikov, A., Richtárik, P., Diskin, M., Ryabinin, M., and Gasnikov, A. (2021).  
Distributed methods with compressed communication for solving variational inequalities, with theoretical guarantees.  
[arXiv preprint arXiv:2110.03313](https://arxiv.org/abs/2110.03313).



Carmon, Y., Jin, Y., Sidford, A., and Tian, K. (2019).  
Variance reduction for matrix games.  
[arXiv preprint arXiv:1907.02056](https://arxiv.org/abs/1907.02056).



Chavdarova, T., Gidel, G., Fleuret, F., and Lacoste-Julien, S. (2019).  
Reducing noise in gan training with variance reduced extragradient.  
[arXiv preprint arXiv:1904.08598](https://arxiv.org/abs/1904.08598).

-  Gorbunov, E., Berard, H., Gidel, G., and Loizou, N. (2021).  
Stochastic extragradient: General analysis and improved rates.  
[arXiv preprint arXiv:2111.08611](https://arxiv.org/abs/2111.08611).
-  Hsieh, Y.-G., Iutzeler, F., Malick, J., and Mertikopoulos, P. (2019).  
On the convergence of single-call stochastic extra-gradient methods.  
[Advances in Neural Information Processing Systems](#), 32.
-  Juditsky, A., Nemirovski, A., and Tauvel, C. (2011).  
Solving variational inequalities with stochastic mirror-prox algorithm.  
[Stochastic Systems](#), 1(1):17–58.
-  Korpelevich, G. M. (1976).  
The extragradient method for finding saddle points and other problems.  
[Matecon](#), 12:747–756.
-  Kovalev, D., Beznosikov, A., Sadiev, A., Pershianov, M., Richtárik, P., and Gasnikov, A. (2022).  
Optimal algorithms for decentralized stochastic variational inequalities.  
[arXiv preprint arXiv:2202.02771](https://arxiv.org/abs/2202.02771).

-  Mishchenko, K., Kovalev, D., Shulgin, E., Richtárik, P., and Malitsky, Y. (2020).  
Revisiting stochastic extragradient.  
In International Conference on Artificial Intelligence and Statistics, pages 4573–4582. PMLR.
-  Nemirovski, A. (2004).  
Prox-method with rate of convergence  $o(1/t)$  for variational inequalities with Lipschitz continuous monotone operators and smooth convex-concave saddle point problems.  
SIAM Journal on Optimization, 15:229–251.
-  Palaniappan, B. and Bach, F. (2016).  
Stochastic variance reduction methods for saddle-point problems.  
In Advances in Neural Information Processing Systems, pages 1416–1424.
-  Popov, L. D. (1980).  
A modification of the arrow-hurwicz method for search of saddle points.  
Mathematical notes of the Academy of Sciences of the USSR, 28(5):845–848.



Tominin, V., Tominin, Y., Borodich, E., Kovalev, D., Gasnikov, A., and Dvurechensky, P. (2021).

On accelerated methods for saddle-point problems with composite structure.  
[arXiv preprint arXiv:2103.09344](https://arxiv.org/abs/2103.09344).



Yang, J., Kiyavash, N., and He, N. (2020).

Global convergence and variance-reduced optimization for a class of nonconvex-nonconcave minimax problems.  
[arXiv preprint arXiv:2002.09621](https://arxiv.org/abs/2002.09621).