



Skolkovo Institute of Science and Technology

Специальность: 1.2.2

Математическое моделирование, численные методы и комплексы программ

---

# Параметрические методы вычисления оптимальных транспортных расстояний, отображений и барицентров

---

Соискатель: Коротин А.А.

Научный руководитель: д.ф.-м.н., доцент Бурнаев Е.В.

2022

## Характеристика работы

Актуальность исследования

Постановка задач исследования

Публикации и результаты

## Содержание работы

- Численный метод для моделирования Васерштейн-2 отображений (гл. 2)
- Численный метод для Васерштейн-2 барицентра (гл. 3)
- Численный метод для моделирования Васерштейн-2 градиентного потока (гл. 4)
- Методология построения эталонных пар для Васерштейн-2 (гл. 5)

## Заключение


## Характеристика работы

---

# Сценарии моделирования данных в машинном обучении

## Сценарий 1

Отображение  
2 выборки




Примеры приложений:

синтез искусственных данных,  
доменная адаптация,  
сверхразрешение и перенос  
стиля м/у изображениями

## Сценарий 2

Усреднение  
Набор выборок




Примеры приложений:

смешивание апостериорных  
распределений, агрегация  
вероятностных прогнозов

## Сценарий 3

Моделирование динамики  
Послед. выборка



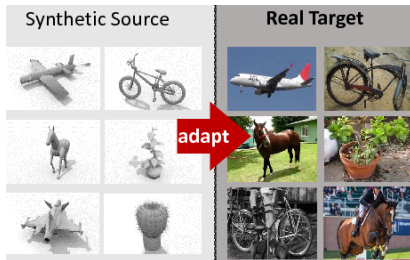
Примеры приложений:

моделирование эволюционных  
процессов в машинном  
обучении, физике, экономике




# Пример сценария 1, требующего сопоставления выборок<sup>1</sup>

## Доменная адаптация



X, Y - наборы данных  
исходного/целевого доменов

## Передача цвета м/у изображениями




X, Y - наборы RGB пикселей

<sup>1</sup>Источники изображений: [ai.bu.edu/syn2real/](http://ai.bu.edu/syn2real/), [github.com/VinceMarron/style\\_transfer](https://github.com/VinceMarron/style_transfer)


## Пример сценария 2, требующего усреднения выборок<sup>23</sup>

### Агрегация выборочных апостериорных распределений



$$p(\theta|D) \approx \text{Barycenter}[p(\theta|D_1), \dots, p(\theta|D_N)]$$

### Смешивание стилей изображений

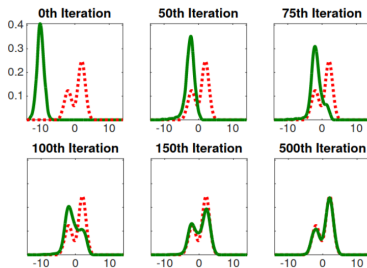


<sup>2</sup>Sanvesh Srivastava, Cheng Li и David B Dunson (2018). “Scalable Bayes via barycenter in Wasserstein space”. B: The Journal of Machine Learning Research 19.1, с. 312—346.


<sup>3</sup>Youssef Mroueh (2020). “Wasserstein Style Transfer”. B: International Conference on Artificial Intelligence and Statistics. PMLR, с. 842—852.

## Моделирование выборки из апостериорного распределения

$$p(\theta|D) \propto p(D|\theta)p(\theta)$$



## Синтез искусственных выборок данных



<sup>4</sup>Qiang Liu и Dilin Wang (2016). “Stein variational gradient descent: A general purpose bayesian inference algorithm”. B: Advances in neural information processing systems 29.

<sup>5</sup>Jiaojiao Fan, Amirhossein Taghvaei и Yongxin Chen (2022). Variational Wasserstein gradient flow. URL: <https://openreview.net/forum?id=WZR7ckBkzPY>.


Предположение: наблюдаемые данные являются случайными выборками из соответствующих вероятностных распределений.

## Сценарий 1

Отображение

2 выборки

$$X \sim \mathbb{P}, Y \sim \mathbb{Q}$$




## Сценарий 2

Усреднение

Набор выборок

$$X_n \sim \mathbb{P}_n$$




## Сценарий 3


Моделирование динамики

Послед. выборки

$$X_t \sim \rho_t$$



В данной диссертационной работе  
развивается арсенал математических методов моделирования для решения ранее  
упомянутых задач на основе подходов теории оптимального транспорта.



Задача оптимальной транспортировки  
массы Монже-Канторовича.




Леонид Витальевич Канторович,  
советский математик и экономист.

<sup>6</sup>Рис.: [microsoft.com/en-us/research/blog/measuring-dataset-similarity-using-optimal-transport/](https://microsoft.com/en-us/research/blog/measuring-dataset-similarity-using-optimal-transport/)

## Задача 1: оптимальный транспорт с квадратичной ценой<sup>7</sup> (по Монже)

Квадрат расстояния Васерштейн-2 между  $\mathbb{P}, \mathbb{Q} \in \mathcal{P}_2(\mathbb{R}^D)$  определяется как

$$W_2^2(\mathbb{P}, \mathbb{Q}) \stackrel{\text{def}}{=} \min_{T: \mathbb{P}=\mathbb{Q}} \int_{\mathbb{R}^D} \frac{\|x - T(x)\|^2}{2} d\mathbb{P}(x).$$



Функция  $T^* : \mathbb{R}^D \rightarrow \mathbb{R}^D$ , доставляющая минимум, называется ОТ отображением.

В случае  $\mathbb{P} \in \mathcal{P}_{2,ac}(\mathbb{R}^D)$   $T^*$  существует, единственно и является градиентом  $\nabla \psi^*$  некоторой выпуклой функции  $\psi^* : \mathbb{R}^D \rightarrow \mathbb{R}$  (Теорема Бренье).


Задача 1: Вычисление оптимального отображения и расстояния Васерштейна-2.

<sup>7</sup>Cédric Villani (2008). Optimal transport: old and new. T. 338. Springer Science & Business Media.

## Задача 2: Барицентры в Васерштейн-2 пространстве распределений<sup>8</sup>

Барицентр (центр масс)  $\bar{\mathbb{P}}$  распределений  $\mathbb{P}_1, \mathbb{P}_2, \dots, \mathbb{P}_N \in \mathcal{P}_2(\mathbb{R}^D)$  с весами  $\alpha_1, \dots, \alpha_N \geq 0$  при  $\sum_{n=1}^N \alpha_n = 1$  определяется как взвешенное среднее по Фреше в пр-ве  $(\mathcal{P}_2(\mathbb{R}^D), W_2)$ :

$$\bar{\mathbb{P}} = \arg \min_{\mathbb{P} \in \mathcal{P}_2(\mathbb{R}^D)} \sum_{n=1}^N \alpha_n W_2^2(\mathbb{P}, \mathbb{P}_n).$$





Задача 2: Вычисление Васерштейн-2 барицентра семейства распределений.

<sup>8</sup>Martial Agueh и Guillaume Carlier (2011). “Barycenters in the Wasserstein space”. B: SIAM Journal on Mathematical Analysis 43.2, с. 904–924.

### Задача 3: Васерштейн-2 градиентные потоки<sup>910</sup>

Многие ДУЧП являются  $\mathcal{W}_2 = \sqrt{2}\mathbb{W}_2$  град. потоками функционалов:

Класс	Ур. $\frac{\partial \rho_t}{\partial t} =$	Функционал $\mathcal{F}(\rho) =$
Ур. теплопроводн.	$\Delta \rho$	$\int_{\mathbb{R}^D} \log \frac{d\rho(x)}{dx} d\rho(x)$
Ур. переноса	$\operatorname{div}(\rho \nabla \Phi)$	$\int_{\mathbb{R}^D} \Phi(x) d\rho(x)$
Ур. Фоккера-Планка	$\operatorname{div}(\rho \nabla \Phi) + \frac{1}{\beta} \Delta \rho$	$\int_{\mathbb{R}^D} \Phi(x) d\rho(x) + \frac{1}{\beta} \int_{\mathbb{R}^D} \log \frac{d\rho(x)}{dx} d\rho(x)$



<sup>9</sup>David Alvarez-Melis, Yair Schiff и Youssef Mroueh (2022). “Optimizing Functionals on the Space of Probabilities with Input Convex Neural Networks”. B: Transactions on Machine Learning Research. URL: <https://openreview.net/forum?id=dpOYN7o8Jm>.

<sup>10</sup>Image source: [https://en.wikipedia.org/wiki/Heat\\_equation](https://en.wikipedia.org/wiki/Heat_equation)



### Задача 3: Васерштейн-2 градиентные потоки<sup>11</sup>

Рассмотрим функционал  $\mathcal{F} : \mathcal{P}_2(\mathbb{R}^D) \rightarrow \mathbb{R}$  на пр-ве вероятностных распределений.


Через  $\mathcal{F}'(\rho)$  обозначим первую вариацию функционала  $\mathcal{F}$  в точке  $\rho$ , т.е. функцию  $f_\rho : \mathbb{R}^D \rightarrow \mathbb{R}$ , для которой

$$\frac{d}{d\epsilon} \mathcal{F}(\rho + \epsilon \chi)|_{\epsilon=0} = \int_{\mathbb{R}^D} f_\rho(x) d\chi(x)$$

для любой меры  $\chi$  со знаком на  $\mathbb{R}^D$  такой, что  $\int 1 d\chi(x) = 0$ , и существует  $\epsilon_0 > 0$ , при котором  $\rho + \epsilon_0 \chi \in \mathcal{P}_2(\mathbb{R}^D)$ .

Васерштейн-2 градиентный поток – непрерывная последовательность  $\{\rho_t\}_{t \in \mathbb{R}_+}$  в  $\mathcal{P}_2(\mathbb{R}^D)$ , удовлетворяющая

$$\frac{\partial \rho_t}{\partial t} - \operatorname{div}(\rho_t \underbrace{\nabla_x \mathcal{F}'(\rho_t)}_{=\partial_{W_2} \mathcal{F}(\rho_t)}) = 0 \quad \text{s.t. } \rho_0 = \rho^0.$$




<sup>11</sup>Filippo Santambrogio (2017). “{Euclidean, metric, and Wasserstein} gradient flows: an overview”. В: Bulletin of Mathematical Sciences 7.1, с. 87–154.

Жордан, Кинделехер и Отто (ЖКО) предложили итеративно вычислять дискретную последовательность  $\rho^1, \rho^2, \dots$ :

$$\rho^{k+1} \leftarrow \arg \min_{\rho \in \mathcal{P}_2(\mathbb{R}^D)} \left[ \mathcal{F}(\rho) + \frac{1}{2\tau} \mathcal{W}_2^2(\rho^k, \rho) \right].$$

При  $\tau \rightarrow 0$  выполняется  $\rho^k \approx \rho_{\tau \cdot k}$ , т.е. дискретизованный поток  $\rho^k$  сходится к истинному потоку  $\rho_t$ .


Практическая имплементация схемы ЖКО нетривиальна, т.к. требует вычисления слагаемого  $\mathcal{W}_2$ .



Задача 3: Вычисление Васерштейн-2 градиентного потока функционала.


<sup>12</sup>Richard Jordan, David Kinderlehrer и Felix Otto (1998). “The variational formulation of the Fokker–Planck equation”. В: SIAM journal on mathematical analysis 29.1, с. 1—17.

## Дискретные



- + выпуклая оптимизация;
- + сильные теор. гарантии;
- слабая масштабируемость;
- нет оценок вне выборки;

## Параметрические (непрерывные)



- ± нейронные сети;
- ± ограниченные теор. гарантии;
- + масштабируемость;
- + оценки вне выборки;

<sup>13</sup>Gabriel Peyré, Marco Cuturi и др. (2019). “Computational optimal transport: With applications to data science”. В: Foundations and Trends® in Machine Learning 11.5-6, с. 355—607.

# Параметрические (непрерывные) двойственные методы: недостатки

Двойственная постановка Канторовича<sup>14</sup> ( $f \in \mathcal{L}^1(\mathbb{P}), g \in \mathcal{L}^1(\mathbb{Q})$ )

$$W_2^2(\mathbb{P}, \mathbb{Q}) = \max_{f, g} \left[ \int_{\mathbb{R}^D} f(x) d\mathbb{P}(x) + \int_{\mathbb{R}^D} g(y) d\mathbb{Q}(y) \right] \quad \text{s.t. } f(x) + g(y) \leq \frac{\|x - y\|^2}{2}.$$

Большинство непрерывных методов решают двойственную задачу, т.е., находят  $f^*$ , и восстанавливают решение прямой задачи, используя  $T^*(x) = x - \nabla f^*(x)$ .

1. Регуляризованный ОТ: наложение мягкого штрафа на  $f, g$  за невыполнение условия  $f \oplus g \leq \frac{1}{2} \|\cdot\|^2$ . Данные методы находят смещенное решение задачи;
2. Максиминный ОТ: оптимизация потенциалов  $f, g$  с использованием  $c$ -трансформации. Данные методы склонны к численной нестабильности.


Таким образом, существует необходимость разработки параметрических численных методов, позволяющих находить ОТ без смещения и максиминной оптимизации.

<sup>14</sup>Cédric Villani (2008). Optimal transport: old and new. T. 338. Springer Science & Business Media.

## Задача 4: Построение эталонных пар для Васерштейн-2 ОТ

Вопрос: как оценить качество восстановленного отображения  $T : \mathbb{R}^D \rightarrow \mathbb{R}^D$  в задаче ОТ?

Проблема: существует ограниченное число пар непрерывных распределений  $\mathbb{P}, \mathbb{Q}$ , для которых аналитически известно истинное оптимальное транспортное отображение  $\nabla\psi^*$ .



Таким образом, требуется разработка количественной методики тестирования непрерывных методов вычисления ОТ.

Задача 4: Построение эталонных пар распределений для Васерштейн-2 ОТ.

# Положения, выносимые на защиту (1 положение = 1 глава работы)

---

1. Предложен неминимаксный алгоритм для вычисления Васерштейн-2 оптимального отображения и расстояния между непрерывными распределениями, базирующийся на нейронных сетях с выпуклой по входу архитектурой и применении разработанной циклической регуляризации в двойственной задаче. Получены теоретические оценки, связывающие ошибку минимизации разработанного целевого функционала с ошибкой решения целевой задачи нахождения отображения. [прим.: задача 1]
2. Предложен неминимаксный алгоритм для вычисления Васерштейн-2 барицентра семейства непрерывных распределений, базирующийся на нейронных сетях с выпуклой по входу архитектурой и использовании разработанных циклической регуляризации и регуляризации на конгруэнтность двойственных переменных задачи. Получены теоретические оценки, связывающие ошибку минимизации разработанного целевого функционала с ошибкой решения целевой задачи нахождения барицентра. [прим.: задача 2]
3. Предложен численный метод имплементации схемы ЖКО для моделирования Васерштейн-2 градиентных потоков функционалов на пространствах многомерных вероятностных распределений с помощью использования нейронных сетей выпуклых по входу. [прим.: задача 3]
4. Разработана методология на основе нейронных сетей с выпуклой по входу архитектурой для синтеза пар непрерывных распределений с аналитически известным ОТ отображением между ними. Данная разработка позволяет заполнить имеющийся пробел в тестировании непрерывных методов решения задачи ОТ и исследования математических моделей, на которых они основаны. [прим.: задача 4]

Результаты диссертационной работы опубликованы в 5 научных статьях в трудах 3 конференций [ранг **Core A\***], из них 2 работы [A1, A2] – индексируемы Scopus.

- A1 (**Core A\***, **Scopus**) Korotin, A., Li, L., Genevay, A., Solomon, J. M., Filippov, A., & Burnaev, E. (2021). Do neural optimal transport solvers work? a continuous wasserstein-2 benchmark. Advances in Neural Information Processing Systems, 34, 14593-14605.
- A2 (**Core A\***, **Scopus**) Mokrov, P., Korotin, A., Li, L., Genevay, A., Solomon, J. M., & Burnaev, E. (2021). Large-scale wasserstein gradient flows. Advances in Neural Information Processing Systems, 34, 15243-15256.
- A3 (**Core A\***) Korotin, A., Egiazarian, V., Asadulaev, A., Safin, A., & Burnaev, E. (2020, September). Wasserstein-2 Generative Networks. In International Conference on Learning Representations.
- A4 (**Core A\***) Korotin, A., Li, L., Solomon, J., & Burnaev, E. (2020, September). Continuous Wasserstein-2 Barycenter Estimation without Minimax Optimization. In International Conference on Learning Representations.
- A5 (**Core A\***) Rout, L., Korotin, A., & Burnaev, E. (2021, September). Generative Modeling with Optimal Transport Maps. In International Conference on Learning Representations.

Работы [A1-A5] суммарно имеют 100+ цитирований согласно научной базе Google Scholar.

## Презентации на международных конференциях

05.2021  
[x2] International Conference on Learning Representations 2021  
ICLR 2021, Core A\*, Онлайн  
Доклад: Wasserstein-2 Generative Networks  
Доклад: Continuous Wasserstein-2 Barycenter Estimation without Minimax Optimization



12.2021  
[x2] Neural Information Processing Systems 2021  
NeurIPS 2021, Core A\*, Онлайн  
Доклад: Large-Scale Wasserstein Gradient Flows  
Доклад: Do Neural Optimal Transport Solvers Work? A Continuous Wasserstein-2 Benchmark



05.2022 International Conference on Learning Representations 2021  
ICLR 2022, Core A\*, Онлайн  
Доклад: Generative Modeling with Optimal Transport Maps




Программный код для разработанных моделей публично доступен по ссылке  
[github.com/iamalexkorotin](https://github.com/iamalexkorotin)



## Презентации на научных семинарах и воркшопх

- 10.2019 Huawei Machine Learning Workshop (Sochi, Russia)  
Доклад: Generative Models [Best presentation award]
- 06.2020 Seminar of the Geometric Data Processing Group (Онлайн)  
Доклад: Wasserstein-2 Generative Networks
- 02.2020 Math of Machine Learning School 2020 (Онлайн)  
Доклад: Wasserstein-2 Generative Networks
- 09.2020 SMILES Machine Learning Summer School 2020 (Онлайн)  
Доклад: Wasserstein-2 Generative Networks
- 12.2020 Research Seminar on Bayesian Methods in ML (Онлайн)  
Доклад: Wasserstein-2 Generative Networks





Научная премия **Я**ндекса имени Ильи Сегаловича  
для студентов, проводящих передовые исследования в области машинного обучения.


Лауреат премии в 2019 и 2021 годах

# Содержание работы

---

### Задача 1

Вычисление Васерштейн-2 оптимального отображения.



### Результат главы

Предложен новый одноэтапный нейросетевой метод для вычисления Васерштейн-2 оптимальных транспортных отображений между непрерывными распределениями без внесения смещения или минимаксной оптимизации.

# Предлагаемый неминимаксный функционал для оптимизации

Минимаксный модход (существующее решение)<sup>15</sup>

$$\min_{\psi \in \text{Convex}} \left[ \int \psi(x) d\mathbb{P}(x) + \int \bar{\psi}(y) d\mathbb{Q}(y) \right] =$$
$$\min_{\psi \in \text{Conv}} \max_{\phi \in \text{Conv}} \left[ \underbrace{\int \psi(x) d\mathbb{P}(x) + \int [\langle \nabla \phi(y), y \rangle - \psi(\nabla \phi(y))] d\mathbb{Q}(y)}_{\text{Corr}(\mathbb{P}, \mathbb{Q} | \psi, \phi)} \right]$$

Предлагаемый неминимаксный подход: циклический регуляризатор ( $\lambda > 0$ )

$$\min_{\psi, \phi \in \text{Conv}} \text{Corr}(\mathbb{P}, \mathbb{Q} | \psi, \phi; \lambda) \stackrel{\text{def}}{=} \min_{\psi, \phi \in \text{Conv}} \left[ \underbrace{\text{Corr}(\mathbb{P}, \mathbb{Q} | \psi, \phi) + \int_y \frac{\lambda}{2} \|\nabla \psi(\nabla \phi(y)) - y\|^2 d\mathbb{Q}(y)}_{\text{Цикл. рег. } \mathcal{R}_2^{\mathbb{Q}}(\psi, \phi)} \right].$$


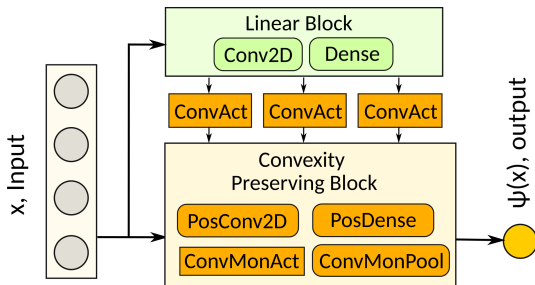
На практике предлагается аппроксимировать  $\{\psi, \phi\}$  выпуклыми по входу нейросетями и тренировать их параметры с помощью стохастического град. спуска на выборках из  $\mathbb{P}, \mathbb{Q}$ .

<sup>15</sup>Ashok Makkuva и др. (2020). “Optimal transport mapping via input convex neural networks”. В: International Conference on Machine Learning. PMLR, с. 6672—6681.

# Выпуклые по входу нейронные сети (ICNN)

Выпуклые функции можно аппроксимировать нейросетями  $\psi(x) : \mathbb{R}^D \rightarrow \mathbb{R}$ .

- $\psi_\theta : \mathbb{R}^D \rightarrow \mathbb{R}$  – глубокая выпуклая по входу нейросеть<sup>16</sup> (ICNN);
- $T_\theta = \nabla_x \psi_\theta : \mathbb{R}^D \rightarrow \mathbb{R}^D$  - транспортное отображение.



<sup>16</sup>Brandon Amos, Lei Xu и J Zico Kolter (2017). “Input convex neural networks”. B: Proceedings of the 34th International Conference on Machine Learning-Volume 70. JMLR. org, c. 146–155.

Теорема 1. Связь решений предложенной двойственной и прямой задач

Пусть  $\mathbb{P}, \mathbb{Q} \in \mathcal{P}_{2,ac}(\mathbb{R}^D)$ . Пусть  $\psi^* : \mathbb{R}^D \rightarrow \mathbb{R}$  – оптимальный выпуклый потенциал:

$$\psi^* = \arg \min_{\psi \in \text{Convex}} \text{Corr}(\mathbb{P}, \mathbb{Q} | \psi) = \arg \min_{\psi \in \text{Convex}} \left[ \int_{\mathbb{R}^D} \psi(x) d\mathbb{P}(x) + \int_{\mathbb{R}^D} \bar{\psi}(y) d\mathbb{Q}(y) \right].$$

Пусть дифф. выпуклые функции  $\hat{\psi}, \hat{\phi} : \mathbb{R}^D \rightarrow \mathbb{R}$  таковы, что, при некотором  $\epsilon \in \mathbb{R}$ ,

$$\text{Corr}(\mathbb{P}, \mathbb{Q} | \hat{\psi}, \hat{\phi}; \lambda) \leq \left[ \int_{\mathbb{R}^D} \psi^*(x) d\mathbb{P}(x) + \int_{\mathbb{R}^D} \bar{\psi}^*(y) d\mathbb{Q}(y) \right] + \epsilon = \text{Corr}(\mathbb{P}, \mathbb{Q} | \psi^*) + \epsilon. \quad (1)$$

Предположим, что  $\hat{\psi}$  является  $\beta$ -сильно выпуклой ( $\beta > \frac{1}{\lambda} > 0$ ) и  $\mathcal{B}$ -гладкой ( $\mathcal{B} \geq \beta$ ). Предположим также, что  $\hat{\phi}$  имеет биективный градиент  $\nabla \hat{\phi}$ . Тогда выполнено:

1. Оценка сверху для корреляции

$$\text{Corr}(\mathbb{P}, \mathbb{Q} | \hat{\psi}, \hat{\phi}; \lambda) \geq \text{Corr}(\mathbb{P}, \mathbb{Q} | \psi^*) \quad (\text{т.е. } \epsilon \geq 0);$$

2. Прямое и обратное транспортные свойства

$$\frac{1}{2} \int_{\mathbb{R}^D} \|\nabla \hat{\psi}(x) - \nabla \psi^*(x)\|^2 d\mathbb{P}(x) \leq \frac{(\mathcal{B})^2 \cdot \epsilon}{\lambda \beta - 1} \cdot \left[ \frac{1}{\sqrt{\beta}} + \sqrt{\lambda} \right]^2 = O(\epsilon);$$

$$\frac{1}{2} \int_{\mathbb{R}^D} \|\nabla \hat{\phi}(y) - \nabla \bar{\psi}^*(y)\|^2 d\mathbb{Q}(y) \leq \frac{\epsilon}{\beta - \frac{1}{\lambda}} = O(\epsilon).$$

## Теорема 2. Свойство решений в ограниченном классе функций

Пусть  $\mathbb{P}, \mathbb{Q} \in \mathcal{P}_{2,\text{ac}}(\mathbb{R}^D)$ . Пусть  $\psi^* : \mathbb{R}^D \rightarrow \mathbb{R}$  – оптимальный выпуклый потенциал. Далее, пусть  $\Psi, \Phi$  – классы дифференцируемых выпуклых функций  $\mathbb{R}^D \rightarrow \mathbb{R}$  соответственно. Предположим, что

1.  $\exists \psi_1 \in \Psi$  с  $\epsilon_1$ -близким градиентом прямого отображения  $\nabla \psi^*$  в смысле  $\mathcal{L}^2(\mathbb{R}^D \rightarrow \mathbb{R}^D, \mathbb{P})$ :

$$\|\nabla \psi_1 - \nabla \psi^*\|_{\mathbb{P}}^2 \stackrel{\text{def}}{=} \int_{\mathbb{R}^D} \|\nabla \psi_1(y) - \nabla \psi^*(y)\|^2 d\mathbb{P}(y) \leq \epsilon_1,$$

где  $\psi_1$  является  $\mathcal{B}$ -гладкой;

2.  $\exists \phi_2 \in \Phi$  с  $\epsilon_2$ -близким градиентом к обратному отображению  $\nabla \overline{\psi^*}$  в смысле  $\mathcal{L}^2(\mathbb{R}^D \rightarrow \mathbb{R}^D, \mathbb{Q})$ :

$$\|\nabla \phi_2 - \nabla \overline{\psi^*}\|_{\mathbb{Q}}^2 \stackrel{\text{def}}{=} \int_{\mathbb{R}^D} \|\nabla \phi_2(y) - \nabla \overline{\psi^*}(y)\|^2 d\mathbb{Q}(y) \leq \epsilon_2.$$

Пусть  $(\hat{\psi}, \hat{\phi})$  – минимизаторы рег. корреляций в  $\Psi \times \Phi$ :  $(\hat{\psi}, \hat{\phi}) = \arg \min_{\psi \in \Psi, \phi \in \Phi} \text{Corr}(\mathbb{P}, \mathbb{Q} \mid \psi, \phi; \lambda)$ .

Тогда регуляризованные корреляции для  $(\hat{\psi}, \hat{\phi})$  удовлетворяют следующему неравенству:


$$\text{Corr}(\mathbb{P}, \mathbb{Q} \mid \hat{\psi}, \hat{\phi}; \lambda) \leq \text{Corr}(\mathbb{P}, \mathbb{Q}) + \left[ \frac{\lambda}{2} (\mathcal{B}\sqrt{\epsilon_2} + \sqrt{\epsilon_1})^2 + (\mathcal{B}\sqrt{\epsilon_2} + \sqrt{\epsilon_1}) \cdot (\sqrt{\epsilon_2}) + \frac{\mathcal{B}}{2} \epsilon_2 \right],$$

т.е. регуляризованные корреляции не превышают истинных плюс  $O(\epsilon_1 + \epsilon_2)$ .



## Эксперименты: OT между гауссианами (количественные результаты)


Гауссовский случай:  $\mathbb{P}, \mathbb{Q} = \mathcal{N}(\mu_{\mathbb{P}}, \Sigma_{\mathbb{P}}), \mathcal{N}(\mu_{\mathbb{Q}}, \Sigma_{\mathbb{Q}})$



Metric:

$$\mathcal{L}^2\text{-UVP}(\hat{T}) = 100 \cdot \frac{\|\hat{T} - \nabla \psi^*\|_{\mathbb{P}}^2}{\text{Var}(\mathbb{Q})} \%$$






Размерность	2	4	8	16	32	64	128	256	512	1024	2048	4096
LSOT	< 1	3.7	7.5	14.3	23	34.7	46.9	> 50				
MM-1	< 1	< 1	< 1	< 1	< 1	1.2	1.4	1.3	1.5	1.6	1.8	2.7
MM-2	< 1	< 1	< 1	< 1	< 1	< 1	1	1.1	1.2	1.3	1.5	2.1
W2GN (ours)	< 1	< 1	< 1	< 1	< 1	< 1	1	1.1	1.3	1.3	1.8	1.5



Согласно экспериментальным результатам, предложенный метод работает лучше/сравнимо существующих методов, но эмпирически быстрее сходится.


# Передача цвета: качественные результаты

Входные изображения → выходные изображения



Изображения  $128 \times 128$


Набор изображений Winter2SummerYosemite<sup>17</sup>



<sup>17</sup>Jun-Yan Zhu и др. (2017). “Unpaired image-to-image translation using cycle-consistent adversarial networks”. В: Proceedings of the IEEE international conference on computer vision, с. 2223—2232.

### Задача 2

Вычисление Васерштейн-2 барицентра.



### Результат главы

Предложен нейросетевой метод вычисления барицентров Васерштейна-2 между непрерывными распределениями, основанный на выпуклых по входу нейросетях и неминимаксной оптимизации без смещения.

Прямая постановка:


$$\bar{\mathbb{P}} = \arg \min_{\mathbb{P} \in \mathcal{P}_2(\mathbb{R}^D)} \underbrace{\sum_{n=1}^N \alpha_n W_2^2(\bar{\mathbb{P}}, \mathbb{P}_n)}_{\mathcal{B}(\bar{\mathbb{P}})}.$$

Двойственная постановка:

$$\mathcal{B}(\bar{\mathbb{P}}) = \text{Const} - \underbrace{\min_{\{\psi_n\} \text{ congr.}} \sum_{n=1}^N \alpha_n \int_{\mathbb{R}^D} \psi_n(y) d\mathbb{P}_n(y)}_{\text{MultiCorr}(\{\alpha_n, \mathbb{P}_n\} | \{\psi_n\})},$$

где выпуклые  $\psi_n$  согласованы (конгруэнтны):

$$\forall x \in \mathbb{R}^D : \quad \sum_{n=1}^N \alpha_n \bar{\psi}_n(x) = \frac{\|x\|^2}{2}.$$



Прямая-двойственная связь:

$$\nabla \psi_n^* \# \mathbb{P}_n = \bar{\mathbb{P}}$$

позволяет восстановить  $\bar{\mathbb{P}}$   
из двойственных потенциалов  $\psi_n^*$ .

<sup>18</sup>Martial Agueh и Guillaume Carlier (2011). “Barycenters in the Wasserstein space”. В: SIAM Journal on Mathematical Analysis 43.2, с. 904–924.

# Предложенный неминимаксный функционал оптимизации

Рассмотрим оптимизацию ( $\lambda > 0, \tau \geq 1$ ) по  $2N$  выпуклым функциям  $\{\psi_n, \phi_n\}$ :

$$\min_{\{\psi_n, \phi_n\}} \overbrace{\sum_{n=1}^N \left[ \alpha_n \int_{\mathbb{R}^D} [\langle x, \nabla \psi_n(x) \rangle - \phi_n(\nabla \psi_n(x))] d\mathbb{P}_n(x) \right]}^{\text{Аппроксимация множественных корреляций}} + \underbrace{\tau \cdot \mathcal{R}_1^{\hat{\mathbb{P}}}(\{\phi_n\})}_{\text{Рег. на согл.}} + \underbrace{\lambda \sum_{n=1}^N \alpha_n \mathcal{R}_2^{\mathbb{P}_n}(\psi_n, \phi_n)}_{\text{Цикл. рег.}}.$$

Здесь  $\mathcal{R}_2^{\mathbb{P}_n}(\psi_n, \phi_n)$  – циклические регуляризаторы, а  $\mathcal{R}_1^{\hat{\mathbb{P}}}(\{\phi_n\})$  – новый регуляризатор на согласованность (с вспомогательным распределением  $\hat{\mathbb{P}}$ ):

$$\mathcal{R}_1^{\hat{\mathbb{P}}}(\{\phi_n\}) = \int_{\mathbb{R}^D} \left[ \sum_{n=1}^N \alpha_n \phi_n(y) - \frac{\|y\|^2}{2} \right]_+ d\hat{\mathbb{P}}.$$

На практике предлагается аппроксимировать функции  $\{\psi_n, \phi_n\}$  выпуклыми по входу нейронными сетями и тренировать их параметры с помощью стохастического градиентного спуска, используя случайные выборки из  $\mathbb{P}_n, \hat{\mathbb{P}}$ .

## Теорема 3. Связь решений двойственной и прямой задач


Пусть  $\bar{\mathbb{P}} \in \mathcal{P}_{2,\text{ac}}(\mathbb{R}^D)$  – барицентр для  $\mathbb{P}_1, \dots, \mathbb{P}_N \in \mathcal{P}_{2,\text{ac}}(\mathbb{R}^D)$  с весами  $\alpha_1, \dots, \alpha_N$  и пусть  $\{\psi_n^*\}$  – оптимальные конгруэнтные потенциалы для задачи о барицентре. Предположим, что  $\tau, \hat{\mathbb{P}}$  таковы, что  $\tau \geq 1$  и  $\tau \cdot \hat{\mathbb{P}} \geq \bar{\mathbb{P}}$ . Пусть нам также даны выпуклые потенциалы  $\{\hat{\psi}_n\}$  и  $\beta$ -сильно выпуклые и  $\mathcal{B}$ -гладкие выпуклые потенциалы  $\{\hat{\phi}_n\}$  с  $0 < \beta \leq \mathcal{B} < \infty$  и  $\lambda > \frac{\mathcal{B}}{2\beta^2}$ . Положим

$$\epsilon = \text{MultiCorr}(\{\alpha_n, \mathbb{P}_n\} \mid \{\hat{\psi}_n\}, \{\hat{\phi}_n\}; \tau, \hat{\mathbb{P}}, \lambda) - \text{MultiCorr}(\{\alpha_n, \mathbb{P}_n\} \mid \{\psi_n^*\}).$$

Тогда имеем  $\epsilon \geq 0$  и при всех  $n \in \{1, \dots, N\}$

$$\int_{\mathbb{R}^D} \|\nabla \hat{\psi}_n(y) - \nabla \psi^*(y)\|^2 d\mathbb{P}_n(y) \leq \frac{2\epsilon}{\alpha_n} \cdot \left( \sqrt{\frac{1}{\beta}} + \sqrt{\frac{1}{\lambda\beta^2 - \frac{\mathcal{B}}{2}}} \right)^2 = O(\epsilon), \quad (2)$$

что, в частности, означает  $\mathbb{W}_2^2(\nabla \hat{\psi}_n \# \mathbb{P}_n, \bar{\mathbb{P}})$ .



Метрика	Метод	D=2	4	8	16	32	64	128	256
$BW_2^2$ -UVP, %	[FCWB], Cuturi и Doucet 2014	0.64	0.77	1.22	3.75	8.92	14.3	18.46	21.64
	[SCW <sub>2</sub> B], Fan, Taghvaei и Chen 2021	0.12	0.10	0.19	0.29	0.46	0.6	1.38	2.9
$\mathcal{L}_2$ -UVP, % (potentials)		0.17	0.12	0.2	0.31	0.47	0.62	1.21	1.52
	[CRWB], L. Li и др. 2020	0.58	1.83	8.09	21.23	55.17	> 100		
	[CW <sub>2</sub> B], ours	0.17	0.08	0.06	0.1	0.2	0.25	0.42	0.82

Таблица 1: Сравнение метрики UVP в линейно-разбросанном случае (cube uniform), N = 4.


Согласно экспериментальным результатам, предложенный метод  
превосходит по качеству существующие методы.

<sup>19</sup>Pedro C Álvarez-Esteban и др. (2016). “A fixed-point approach to barycenters in Wasserstein space”. В: Journal of Mathematical Analysis and Applications 441.2, с. 744—762.



### Задача 3

Вычисление Васерштейн-2 градиентного потока.



### Результат главы

Предложен численный метод имплементации схемы ЖКО для моделирования Васерштейн-2 градиентных потоков функционалов на пространствах многомерных вероятностных распределений с помощью использования нейронных сетей.

# Предлагаемый алгоритм вычисления Васерштейн-2 градиентного потока

Напомним шаг ЖКО схемы:


$$\rho^{k+1} \leftarrow \arg \min_{\rho \in \mathcal{P}_2(\mathbb{R}^D)} [\mathcal{F}(\rho) + \frac{1}{2\tau} \mathcal{W}_2^2(\rho^k, \rho)].$$

В диссертации предлагается заменить оптимизацию по распределениям на эквивалентную оптимизацию по выпуклым функциям  $\psi$ :


$$\psi_k \leftarrow \arg \min_{\psi \in \text{Conv}} [\mathcal{F}(\nabla \psi \# \rho^k) + \frac{1}{\tau} \int_{\mathbb{R}^D} \frac{1}{2} \|x - \nabla \psi(x)\|^2 d\rho^k(x)].$$

При данном подходе  $\rho^k = \nabla \psi_{k-1} \# [\nabla \psi_{k-2} \# [\dots \nabla \psi_0 \# \rho^0]]$ .


Для численного осуществления шагов ЖКО предлагается обучать последовательность выпуклых по входу нейронных сетей  $\{\psi_k\}$  и оптимизировать их параметры с помощью стохастического градиентного спуска, используя случайные выборки из  $\rho^k$ .



При  $\Phi(x) = \frac{1}{2}(x - b)^T A(x - b)$  с  $A \succeq 0$  и гауссовским  $\rho^0$  град. поток функ-ла  $\mathcal{F}_{FP}(\rho) = \int_{\mathbb{R}^D} \Phi(x) d\rho(x) + \frac{1}{\beta} \int_{\mathbb{R}^D} \log \frac{d\rho(x)}{dx} d\rho(x)$  аналитически вычислим для всех  $t \geq 0$ .<sup>20</sup>



$t = 0.5$



$t = 0.8$

Согласно экспериментальным результатам, предложенный метод превосходит по качеству существующие методы (для сравнения используется метрика SymKL).


<sup>20</sup>Pat Vatiwutipong и Nattakorn Phewchean (2019). “Alternative way to derive the distribution of the multivariate Ornstein–Uhlenbeck process”. B: Advances in Difference Equations 276.

# Качественное сравнение: сходимость к стационарному распределению

Стартуя из начальной точки  $\rho^0$ , градиентный поток  $\mathcal{F}_{\text{FP}}$  сходится к<sup>21</sup>

$$\frac{d\rho^*}{dx}(x) = Z^{-1} \exp(-\beta\Phi(x)),$$

где  $Z = \int_{\mathbb{R}^D} \exp(-\beta\Phi(x))dx$  – нормировочная константа.




2 главные компоненты стационарного и обученного распределений,  $D = 13$  (слева) и  $D = 32$  (справа).

<sup>21</sup>Hannes. Risken (1996). The Fokker-Planck Equation: Methods of Solution and Applications (Springer Series in Synergetics). Springer,

### Задача 4

Построение эталонных пар для Васерштейн-2 транспорта.




### Результат главы

Предложена общая методология построения пар непрерывных распределений с аналитически известными ОТ отображениями для квадратичной стоимости для тестирования параметрических методов ОТ.


## Ключевая предложенная идея построения эталонных пар

Для  $\mathbb{P} \in \mathcal{P}_{2,ac}(\mathbb{R}^D)$  пусть  $\nabla\psi\#\mathbb{P}$  будет его образом под действием градиента выпуклой функции  $\psi : \mathbb{R}^D \rightarrow \mathbb{R}$ .



Тогда  $\nabla\psi$  является ОТ отображением между  $\mathbb{P}$  и  $\nabla\psi\#\mathbb{P}$ .

Предлагается приближать ОТ отображение с помощью градиента выпуклой по входу нейросети  $\nabla\psi_\theta$




и затем использовать пару  $(\mathbb{P}, \nabla\psi_\theta\#\mathbb{P}) \approx (\mathbb{P}, \mathbb{Q})$  как эталонную с известным ОТ отображением  $\nabla\psi_\theta$ .

В основе предложенной идеи лежит теорема Бренье<sup>22</sup>.

<sup>22</sup>Yann Brenier (1991). “Polar factorization and monotone rearrangement of vector-valued functions”. В: Communications on pure and applied mathematics 44.4, с. 375—417.

## Многомерные пары распределений

$$D = 2, 4, 8, \dots, 256$$



Пары распределений в пространстве изображений (на основе Celeba<sup>23</sup>)

3 пары,  $D = 12288$



<sup>23</sup>Ziwei Liu и др. (дек. 2015). “Deep Learning Face Attributes in the Wild”. В: Proceedings of International Conference on Computer Vision (ICCV).

# Количественные результаты метода на разработанных эталонных парах

Dim	2	4	8	16	32	64	128	256
[W2] (Ours)	0.1	0.7	2.6	3.3	6.0	7.2	2.0	2.7
[W2:R]	0.2	0.9	4.0	5.3	5.2	7.0	2.0	2.7
[MMv1]	0.2	1.0	1.8	1.4	6.9	8.1	2.2	2.6
[MM]	0.1	0.3	0.9	2.2	4.2	3.2	3.1↔	4.1↔
[MM:R]	0.1	0.3	0.7	1.9	2.8	4.5	↔	↔
[MMv2]	0.1	0.68	2.2	3.1	5.3	10.1↔	3.2↔	2.7↔
[MMv2:R]	0.1	0.7	4.4	7.7	5.8	6.8	2.1	2.8
[MM-B]	0.1	0.7	3.1	6.4	12.0	13.9	19.0	22.5
[LS]	5.0	11.6	21.5	31.7	42.1	40.1	46.8	54.7
[L]	14.1	14.9	27.3	41.6	55.3	63.9	63.6	67.4
[QC]	1.5	14.5	28.6	47.2	64.0	75.2	80.5	88.2
[C]	100	100	100	100	100	100	100	100
[ID]	32.7	42.0	58.6	87	121	137	145	153

Размерности  $D = 2, 2^2, \dots, 2^8$ . Оранжевый цвет показывает  $\mathcal{L}^2$ -UVP  $> 10\%$ .

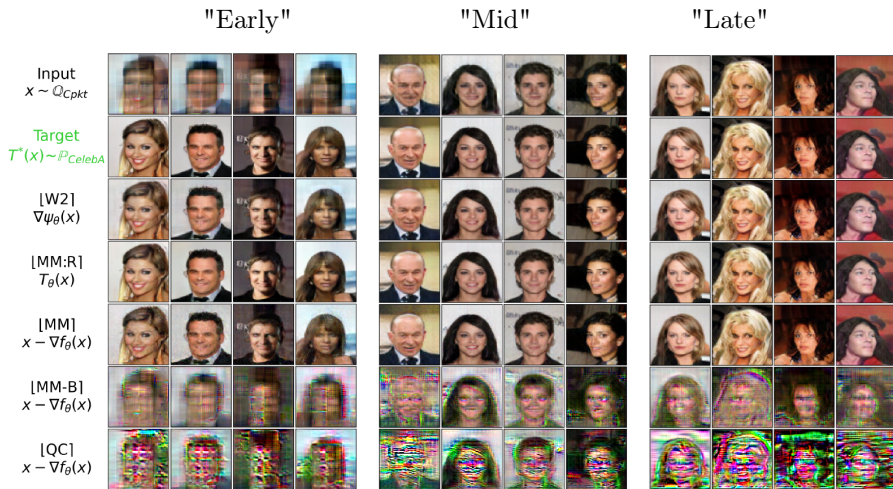
Красный цвет выделяет значения метрики ниже, чем у простого линейного [L] бейзлайна.

Экспериментальные результаты подтверждают, что

1. Седловые методы [MM] численно нестабильны и могут расходиться (↔);
2. Регуляризованный метод [LS] находит смещенное решение;
3. Предложенный метод [W2] стабилен и работает сравнимо/лучше альтернатив.



# Эталонные пары изображений: качественные результаты




## Заключение

---

Итог: 4 задачи  $OT = 4$  решения = 4 положения


### [Задача 1]

Вычисление  $W_2$  OT отображений




### [Задача 2]

Вычисление  $W_2$  барицентров




### [Задача 3]

Вычисление  $W_2$  градиентных потоков




### [Задача 4]

Построение эталонных пар для  $W_2$



Квадрат расстояния Васерштейн-2 между  $\mathbb{P}, \mathbb{Q} \in \mathcal{P}_2(\mathbb{R}^D)$  определяется как

$$W_2^2(\mathbb{P}, \mathbb{Q}) \stackrel{\text{def}}{=} \min_{\pi \in \Pi(\mathbb{P}, \mathbb{Q})} \int_{\mathbb{R}^D \times \mathbb{R}^D} \frac{1}{2} \|x - y\|^2 d\pi(x, y),$$



где минимум берется по всем распределениям  $\pi$  на  $\mathbb{R}^D \times \mathbb{R}^D$ , чьи проекции на первую и вторую компоненту равны  $\mathbb{P}$  и  $\mathbb{Q}$  соответственно.

Распределение  $\pi^* \in \Pi(\mathbb{P}, \mathbb{Q})$ , доставляющее  $\min$ , называется ОТ планом.

<sup>24</sup>Cédric Villani (2008). Optimal transport: old and new. T. 338. Springer Science & Business Media.

Рассмотрим поле скоростей  $v : (x, t) \mapsto v_t(x) \in \mathbb{R}^D$ , для которого выполнено

$$\int_0^T \int_{\mathbb{R}^D} |v_t(x)| d\mu_t(x) dt < \infty.$$

Последовательность распределений  $\{\rho_t\}_{t \in (0, T)}$  является решением уравнения непрерывности

$$\frac{\partial \rho_t}{\partial t} + \operatorname{div}(\rho_t v_t) = 0,$$

если для любой  $h \in C_c^\infty(\mathbb{R}^D)$  выполняется равенство

$$\int_0^T \int_{\mathbb{R}^D} \left( \frac{\partial}{\partial t} h(x, t) + \langle v_t(x), \nabla_x h(x, t) \rangle \right) d\rho_t(x) dt = 0.$$

---

<sup>25</sup>Luigi Ambrosio, Nicola Gigli и Giuseppe Savaré (2005). Gradient flows: in metric spaces and in the space of probability measures. Springer Science & Business Media.

Кривая распределений  $\{\rho_t\}_{t \in [0, T]}$  в  $(\mathcal{P}_2(\mathbb{R}^D), \mathcal{W}_2)$  называется абсолютно непрерывной, если существует  $m \in \mathcal{L}^1([0, T])$  такое, что для любых  $0 < s \leq t < T$  выполнено

$$\mathcal{W}_2(\rho_s, \rho_t) \leq \int_s^t m(r) dr.$$

У такой кривой для почти всех  $t \in [0, T]$  существует предел

$$\lim_{s \rightarrow t} \frac{\mathcal{W}_2(\rho_t, \rho_s)}{|t - s|} = |\rho'| (t),$$

который называется метрической производной. Для почти всех  $t$  верно  $|\rho'| (t) \leq m(t)$ .

Если  $\gamma$  - абсолютно непрерывная (и спрямляемая), то  $L(\rho, [0, T]) = \int_0^T |\rho'| (t) dt$ , где

$$L(\rho, [0, T]) = \sup_{0=s_1 \leq s_2 \leq \dots \leq s_n=T} \sum_{i=1}^{n-1} \mathcal{W}_2(\rho_{s_i}, \rho_{s_{i+1}}) - \text{длина кривой}.$$

---

<sup>26</sup>Полагаем  $\mathcal{W}_2 = \sqrt{2}\mathbb{W}_2$ .

Теорема 8.3.1.<sup>27</sup> Пусть  $I \subset \mathbb{R}$  - открытый интервал и  $\rho_t : I \rightarrow \mathcal{P}_2(\mathbb{R}^D)$  - абсолютно непрерывная кривая. Тогда существует векторное поле  $v : (x, t) \mapsto v_t(x)$ , для которого

$$v_t \in \mathcal{L}^2(\rho_t) \quad \text{и} \quad \|v_t\|_{\mathcal{L}^2(\rho_t)} = |\rho'|_t(t) \quad \text{для п.в. } t \in I,$$

и выполняется уравнение непрерывности


$$\frac{\partial \rho_t}{\partial t} + \operatorname{div}(\rho_t v_t) = 0.$$

При этом  $v_t$  называется касательным полем к кривой  $\rho_t$  и выполнено

$$v_t \in \overline{\{\nabla \phi : \phi \in C_c^\infty\}}_{\mathcal{L}^2(\rho_t)} = \operatorname{Tan}_{\rho_t} \mathcal{P}_2(\mathbb{R}^D),$$

где последнее называется касательным пространством к  $\rho_t$  в  $\mathcal{P}_2(\mathbb{R}^D)$ .

<sup>27</sup>Luigi Ambrosio, Nicola Gigli и Giuseppe Savaré (2005). Gradient flows: in metric spaces and in the space of probability measures. Springer Science & Business Media.



В Евклидовом пространстве $\mathbb{R}^D$	В пространстве распределений $(\mathcal{P}_2(\mathbb{R}^D), \mathcal{W}_2)$
$f : \mathbb{R}^D \rightarrow \mathbb{R}$	$\mathcal{F} : \mathcal{P}_2(\mathbb{R}^D) \rightarrow \mathbb{R}$
$x \in \mathbb{R}^D$	$\mu \in \mathcal{P}_{2,ac}(\mathbb{R}^D)$
$f(y) - f(x) =$ $\langle \xi, y - x \rangle + o(\ y - x\ )$	$\mathcal{F}(\nu) - \mathcal{F}(\mu) =$ $\int_{\mathbb{R}^D} \langle \xi(x), T_{\mu \rightarrow \nu}(x) - x \rangle d\mu(x) + o(\mathcal{W}_2(\mu, \nu))$
Производная по Фреше $\xi \in \partial f(x) \subset \mathbb{R}^D$	$\mathcal{W}_2$ -производная (векторное поле $\mathbb{R}^D \rightarrow \mathbb{R}^D$ ) $\xi \in \partial_{\mathcal{W}_2} \mathcal{F}(\rho) \subset \text{Tan}_\mu \mathcal{P}_2(\mathbb{R}^D)$

<sup>28</sup>Для простоты полагаем, что  $\mu$  абсолютно непрерывно.



В Евклидовом пространстве $\mathbb{R}^D$	В пространстве распределений $(\mathcal{P}_2(\mathbb{R}^D), \mathcal{W}_2)$
$f : \mathbb{R}^D \rightarrow \mathbb{R}$	$\mathcal{F} : \mathcal{P}_2(\mathbb{R}^D) \rightarrow \mathbb{R}$
$x : [0, T] \rightarrow \mathbb{R}^D$	$\rho : [0, T] \rightarrow (\mathcal{P}_2(\mathbb{R}^D), \mathcal{W}_2)$
$\begin{cases} \dot{x}(t) = v_t \\ v_t \in -\partial f(x(t)) \\ x(0) = x^0 \end{cases}$	$\begin{cases} v_t - \text{кас. поле к } \rho_t \\ v_t \in -\partial_{\mathcal{W}_2} \mathcal{F}(\rho_t) \\ \rho_0 = \rho^0 \end{cases}$
$\begin{aligned} \dot{x}(t) &= f'(x(t)), \\ x(0) &= x^0 \end{aligned}$	$\begin{aligned} \frac{\partial \rho_t}{\partial t} - \operatorname{div}(\rho_t \nabla_x \mathcal{F}'(\rho_t)) &= 0, \\ \rho_0 &= \rho^0 \end{aligned}$

<sup>29</sup>В правом столбце используется связь первой вариации и  $\mathcal{W}_2$ -производной:  $\partial_{\mathcal{W}_2} \mathcal{F}(\rho) = \nabla_x \mathcal{F}'(\rho)$ .