Применение генеративных моделей для аугментации обучающих данных в задачах сегментации изображений

Изместьева У.А.
izmesteva.ua@phystech.edu

2 курс магистратуры «Методы и технологии искусственного интеллекта» Центр когнитивного моделирования МФТИ

2025 – Научно-исследовательский семинар

Мотивация

Основания разработки:

- **Расширение данных.** Наборы разнообразных данных повышают устойчивость моделей при обучении.
- **Узкоспециализированные сценарии.** Моделирование специфичных ситуаций помогает решать задачи с ограничениями данных.
- **Снижение стоимости.** Ручной сбор и разметка данных дорогостоящая и подвержена человеческим ошибкам.

Цель: разработать инструмент для автоматической аугментации обучающих данных на основе генеративной модели, способной создавать синтетические данные в заданном домене используя реальные данные и различные модальности.

Постановка задачи

Входные данные:

- набор размеченных изображений;
- карты глубин (опционально);
- текстовые описания объектов (опционально).

Выходные данные:

- аугментированные изображения;
- аугментированные карты глубин;
- список масок, представляющих объекты на входных изображениях (опционально);

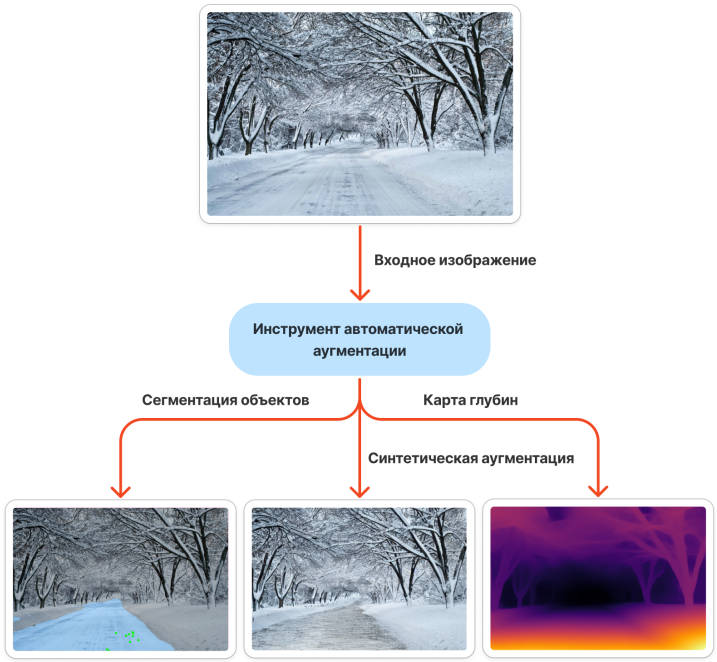

Постановка задачи

Задача состоит в разработке модели F, которая по входным данным X генерирует выходные данные Y. F: $X \rightarrow Y$, где:

- X содержит изображения *(I)*, маски объектов *(M)*, текстовые классы объектов *(T)*;
- Y представляет измененные изображения*(X')* и карты глубины *(D')*.

Математическая формулировка

Пусть $F_\theta(\hat{c})$ - это модель, которая отображает условие текста и маски объекта $\hat{c}$ в условный вектор. Тогда, представление функции потерь $L_{inpaint}$ имеет вид:

$$L_{inpaint} := \mathbb{E}_{z\sim E(x),\hat{y},\epsilon\sim \mathrm{N}(0,1),t}[\|\epsilon - \epsilon_\theta(z_t, t, F_\theta(\hat{c}))\|^2] \tag{2}$$

где:

- t - шаг во времени;
- z_t - латентное изображение, зашумленное в момент времени t;
- ϵ - образец немасштабированного шума;
- θ - нейронная сеть расшумления.

Научная новизна

Научная новизна работы:

- **Функция потерь:** штрафуем модель при попытке сгенерировать "пустоту"и поощряем за генерацию объектов

$$L_{new} := \alpha \|\epsilon_{obj} - \epsilon_\theta(z_t, t, F_\theta(\hat{c}))\|^2 + \frac{\beta}{\|\epsilon_{empt} - \epsilon_\theta(z_t, t, F_\theta(\hat{c}))\|^2 + \gamma} \quad (3)$$

где:

  - ϵ_{obj} - шум GT объекта;
  - ϵ_{empt} - шум синтетически сгенерированной пустоты;
  - $F_\theta(\hat{c})$ - выход модели;
  - α и β - весовые коэффициенты;
  - γ - обработка исключения деления на ноль.

- **Пайплайн генерации синтетических датасетов:** на основе синтетической карты глубины генерировать сцены в желаемом домене + генерация специфических объектов;

Пайплайн генерации синтетических датасетов



Общая схема

Постановка экспериментов

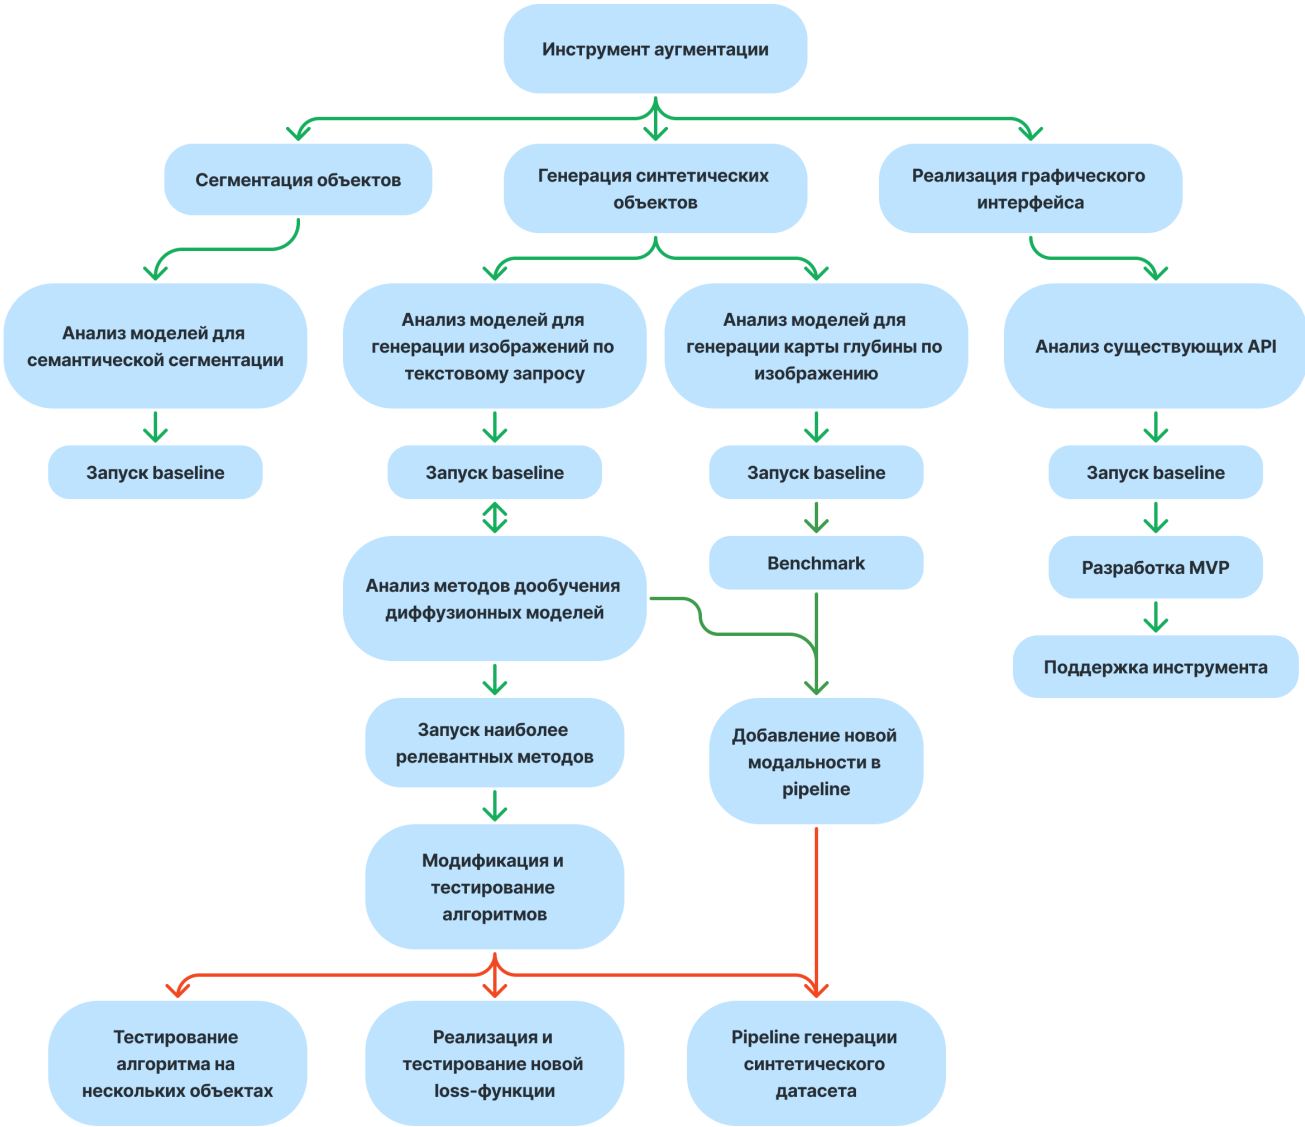

Схема проведенных экспериментов

Стек технологий. Генерация объектов

Генерация изображений в режиме inpainting:

- Stable Diffusion[1]
- PowerPaint[2]

Дообучение диффузионных моделей:

- Textual inversion[3]
- DreamBooth[4]
- LoRA[5]

[1] Rombach R. et al. High-resolution image synthesis with latent diffusion models. – 2022.

[2] Zhuang J. et al. A task is worth one word: Learning with task prompts for high-quality versatile image inpainting – 2023.

[3] Gal R. et al. An image is worth one word: Personalizing text-to-image generation using textual inversion – 2022.

[4] Ruiz N. et al. Dreambooth: Fine tuning text-to-image diffusion models for subject-driven generation – 2023.

[5] Hu E. J. et al. Lora: Low-rank adaptation of large language models – 2021.

Стек технологий. Вычисление глубины

- Depth Anything[6]
- Depth Anything V2[7]
- MaryGold[8]
- DPT[9]

[6] Yang L. et al. Depth anything: Unleashing the power of large-scale unlabeled data – 2024.

[7] Yang L. et al. Depth Anything V2 – 2024.

[8] Ke B. et al. Repurposing diffusion-based image generators for monocular depth estimation – 2024.

[9] Ranftl R., Bochkovskiy A., Koltun V. Vision transformers for dense prediction – 2021.

Используемые методы. Диффузионные модели

Генерация изображений в режиме inpainting - процесс восстановления или восполнения участков изображения по выделенной маске.

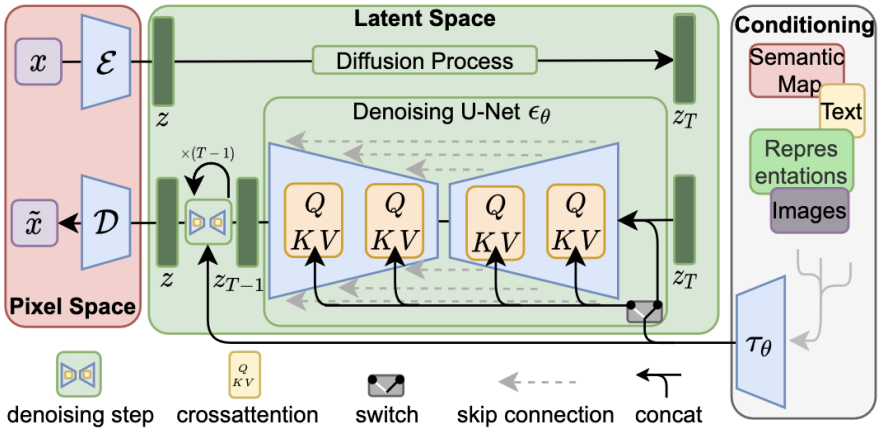

Stable Diffusion 2

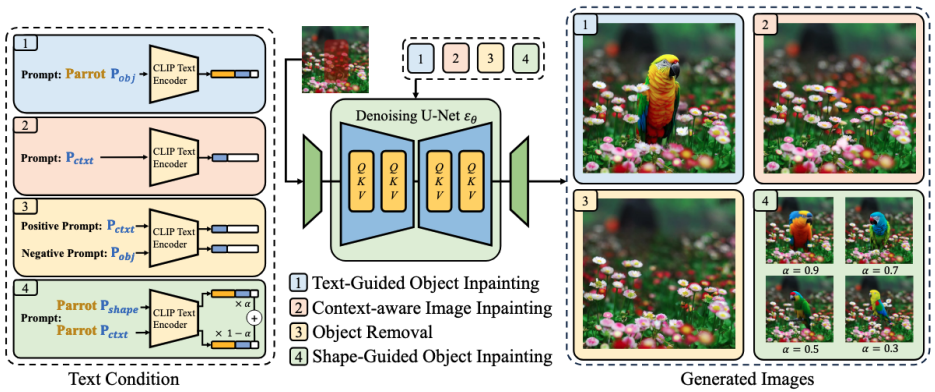

PowerPaint

Используемые методы. Textual inversion

Идея: использовать inpainting веса для генерации объектов в заданной области

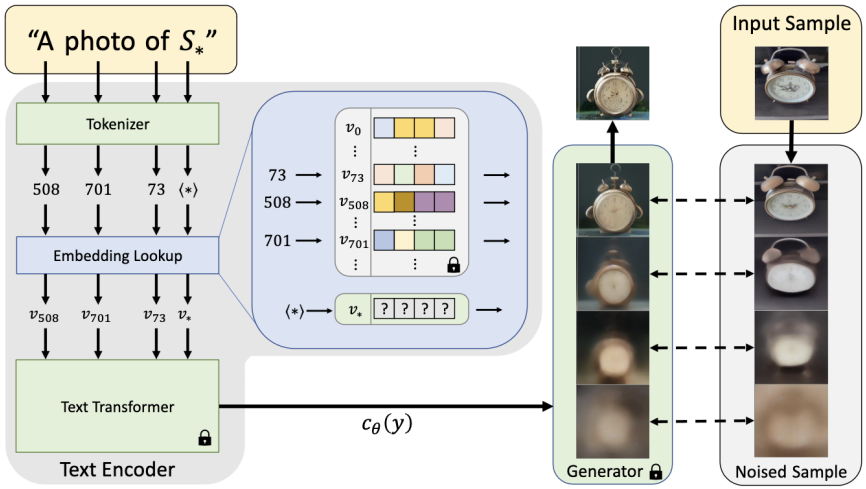

Текстовая инверсия

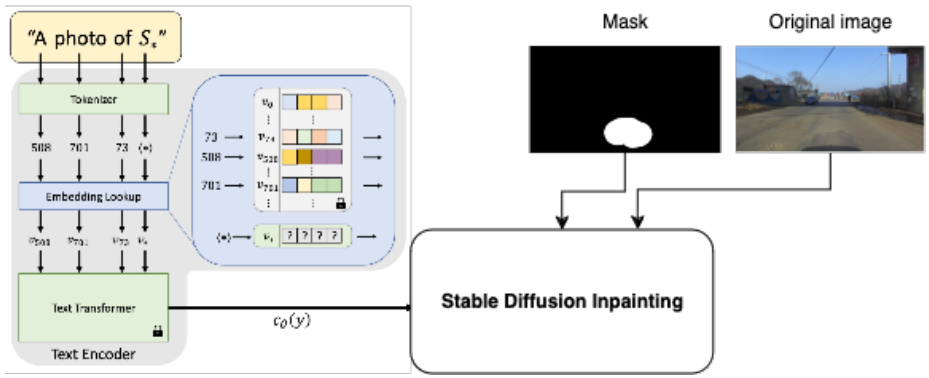

Модифицированный алгоритм

Используемые методы. DreamBooth

Идея: использовать inpainting веса для генерации объектов в заданной области

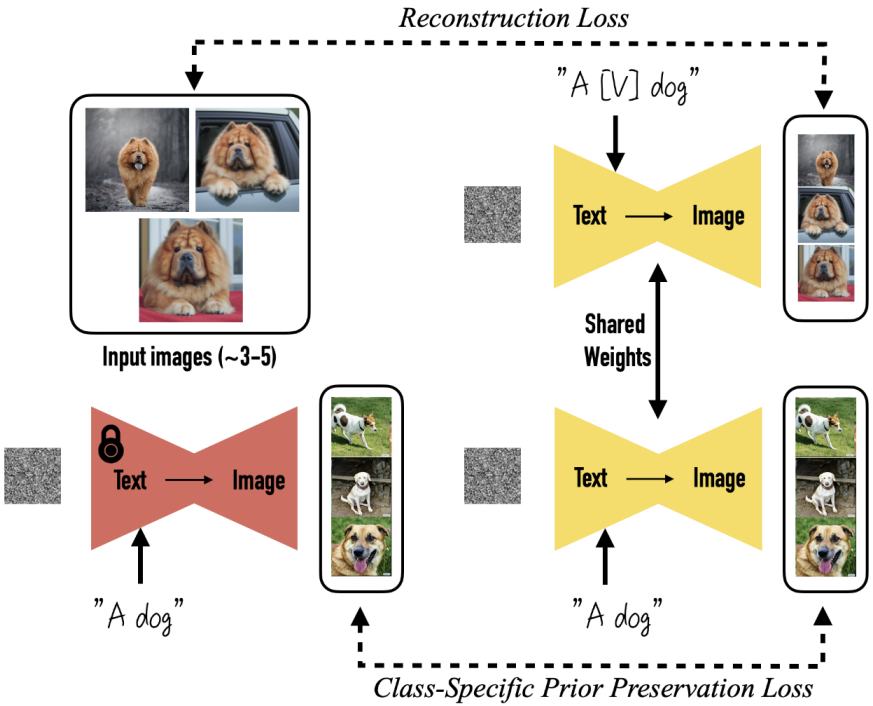

DreamBooth

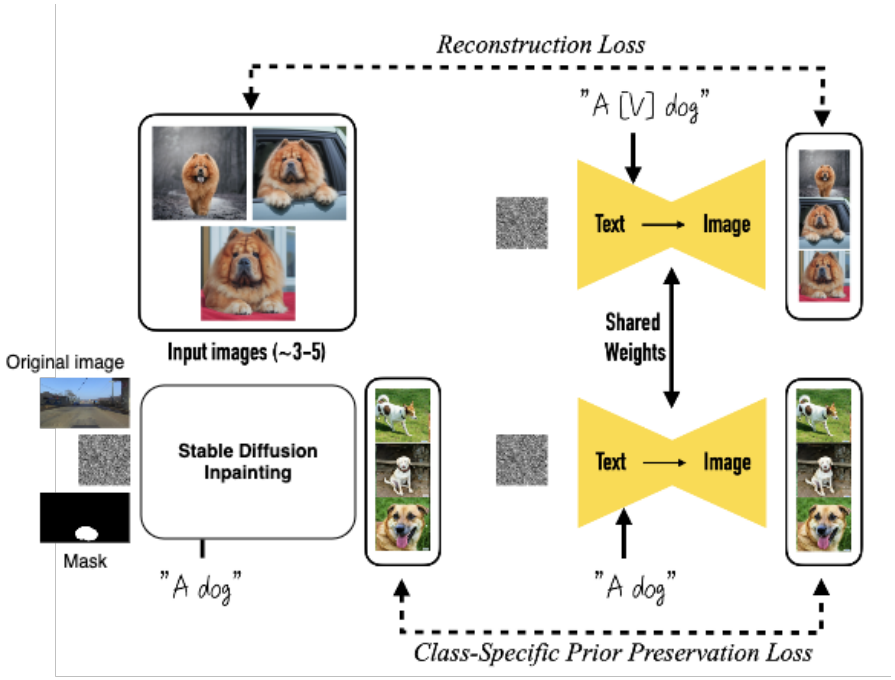

Модифицированный алгоритм

Эксперименты. Генерация объектов

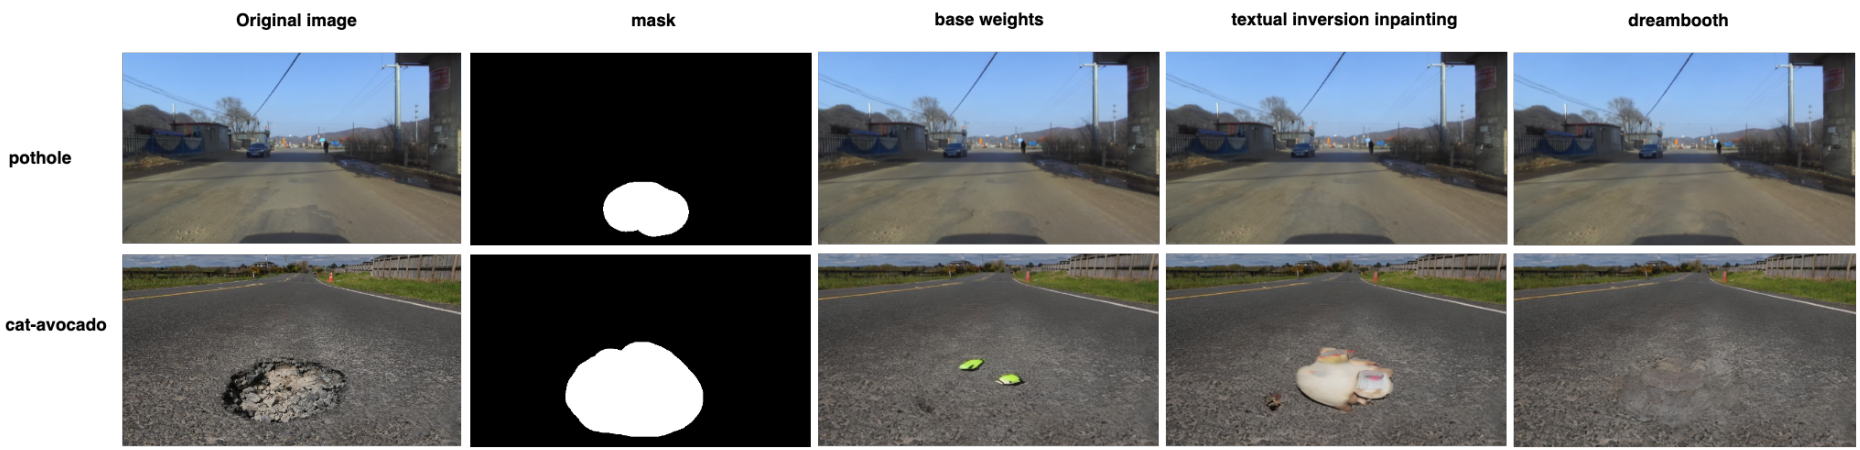

Результаты экспериментов с использованием весов Stable Diffusion 2

Пайплайн генерации синтетических объектов

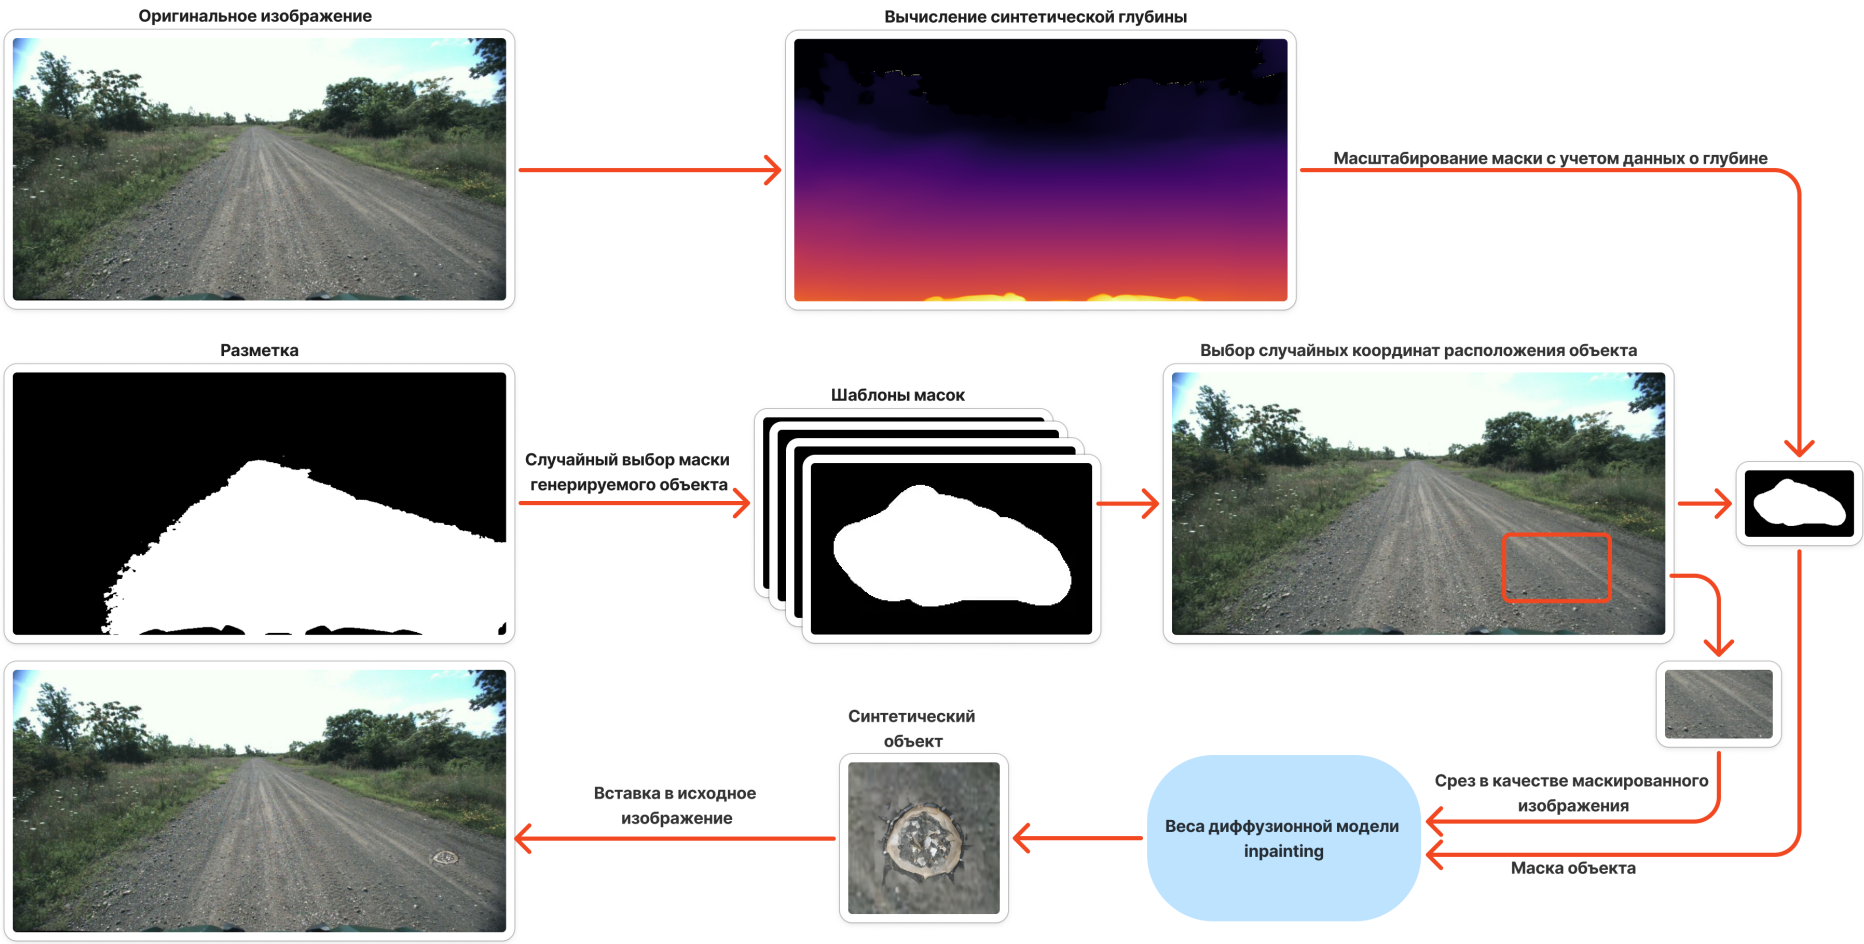

Эксперименты. Генерация объектов

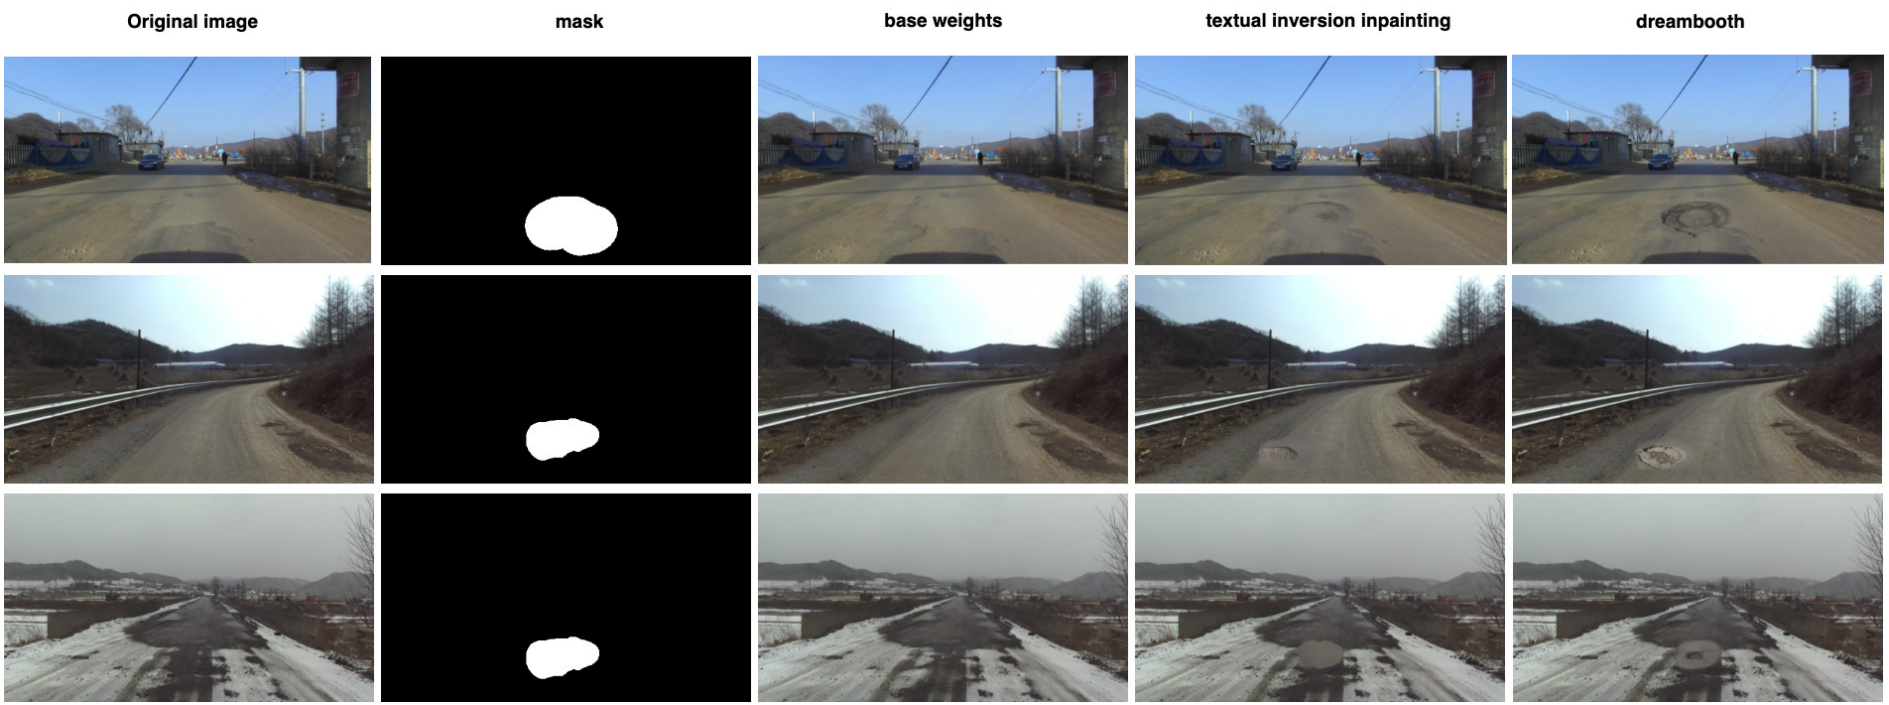

Результаты экспериментов с использованием весов Stable Diffusion 2 и кропов изображений, включающих маску объекта

Используемые методы. LoRA

Идея: использовать inpainting веса для генерации объектов в заданной области

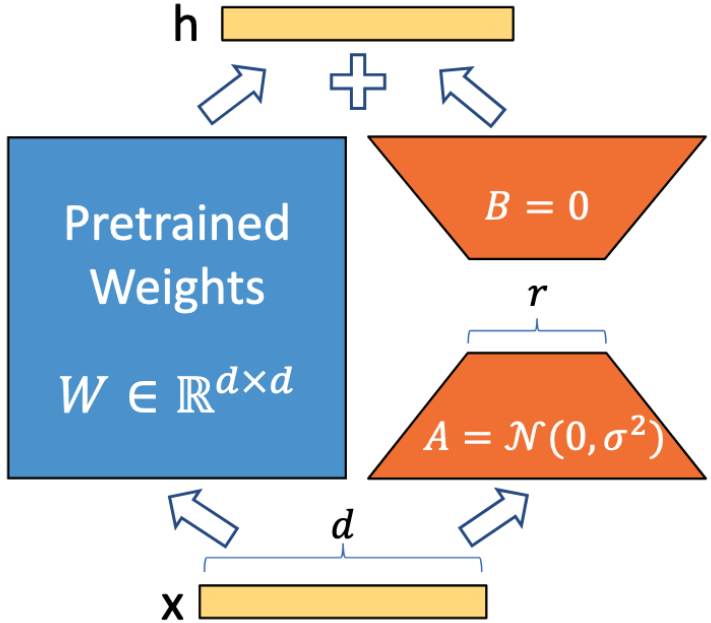

LoRA

Эксперименты. Генерация объектов

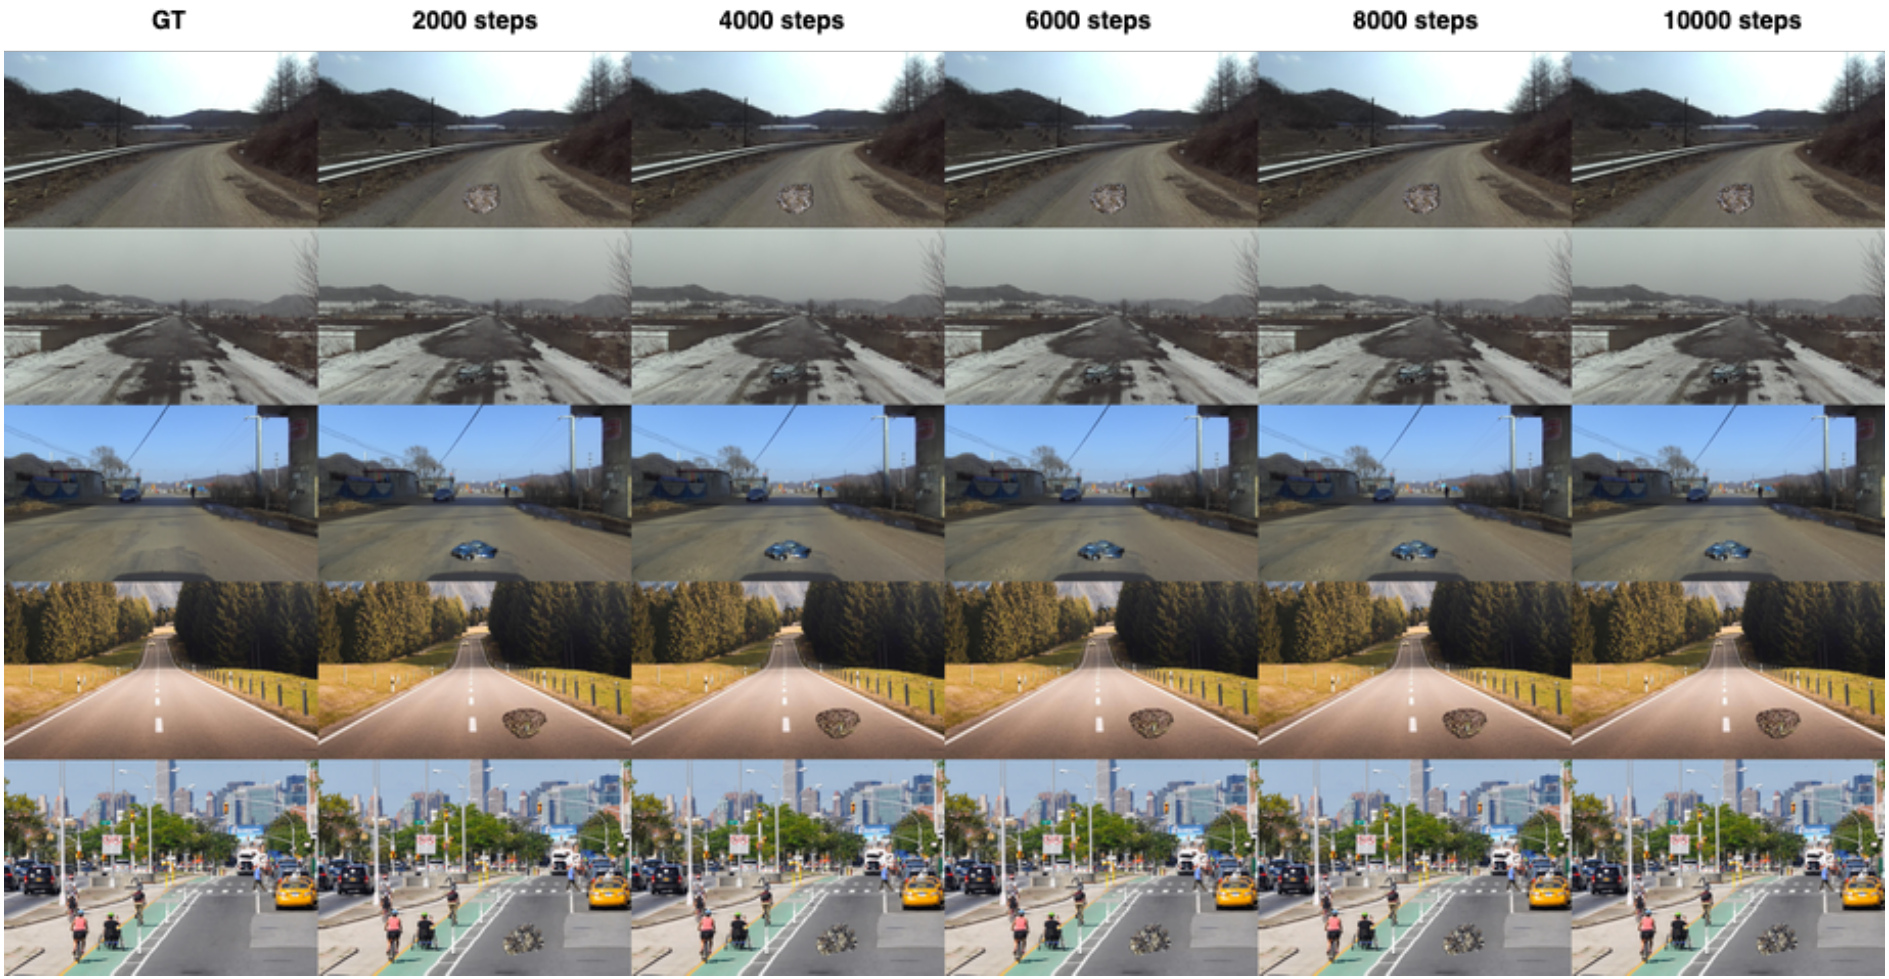

Результаты экспериментов с использованием весов PowerPaint и кропов изображений, включающих маски объекта

Эксперименты. Генерация объектов

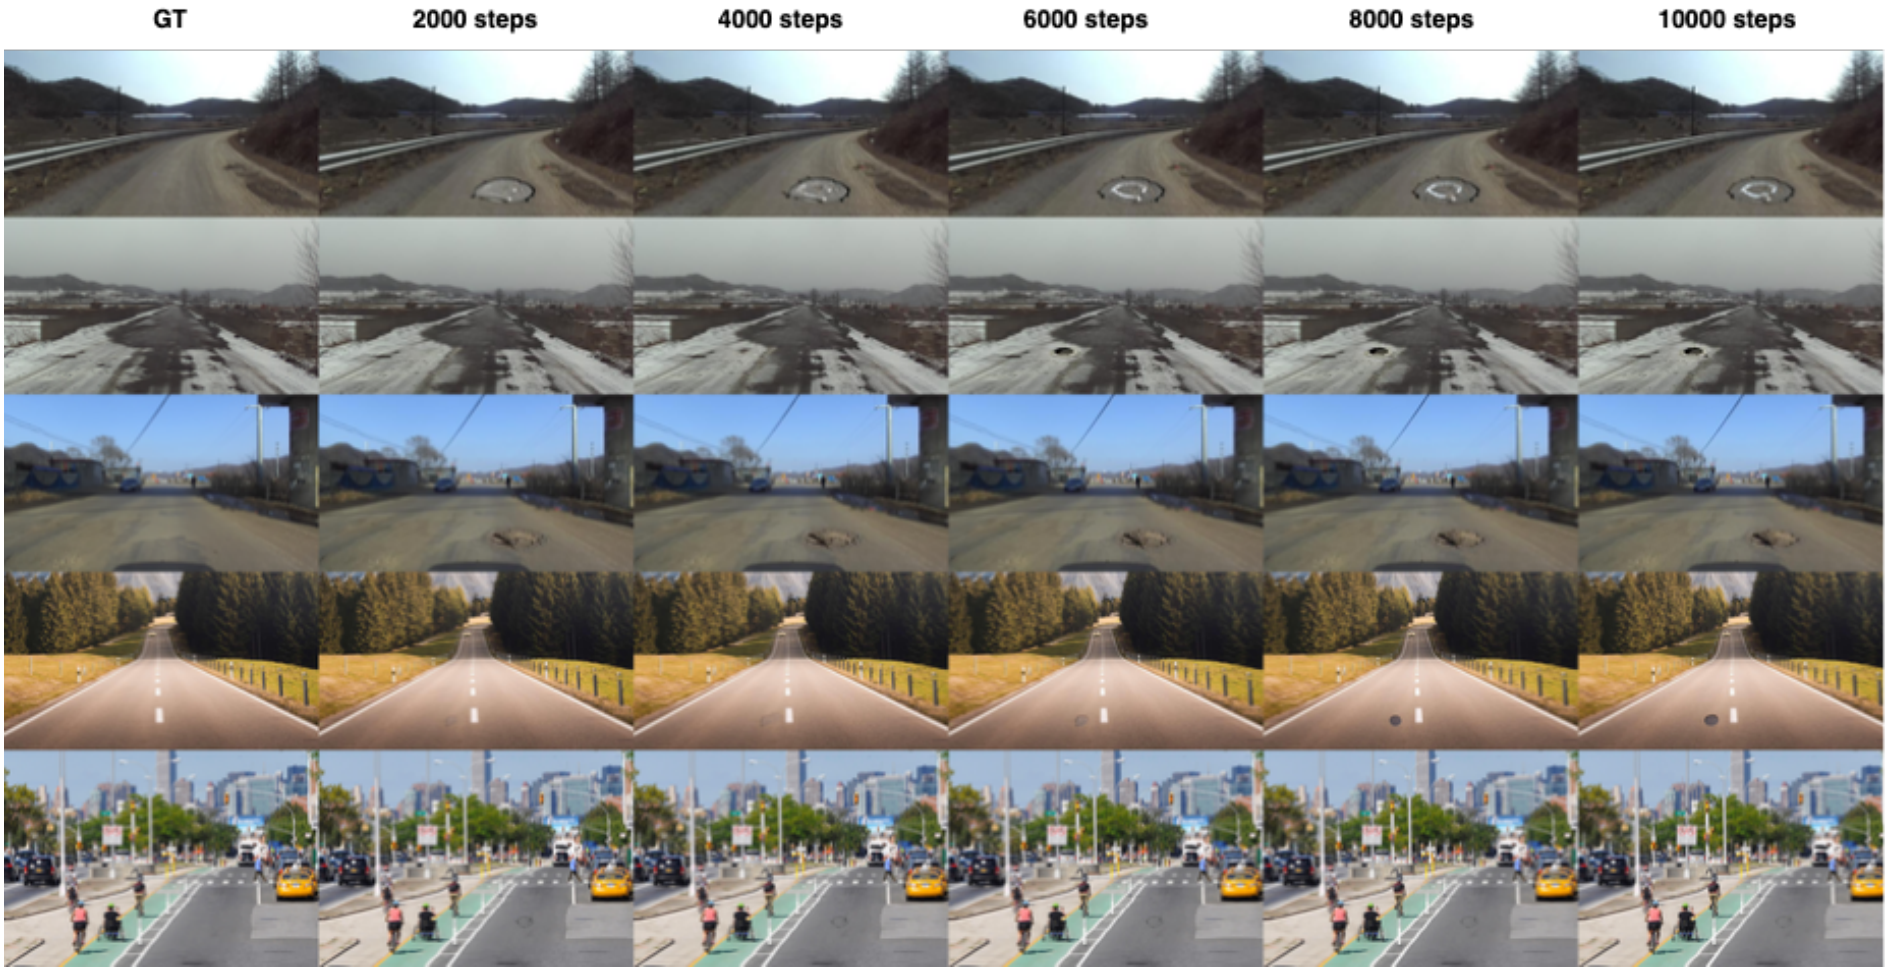

Результаты экспериментов с использованием весов Stable Diffusion 2 и кропов изображений, включающих маски объекта

Эксперименты. Датасет

Category	RR, Yandex and Baidu Images	Masks
Fire hose	272	387
Hose	269	328
Wire	220	231
Animal waste	239	1455
Puddle	273	520
Road bump (pothole or speed bump)	2059	3174
Sidewalk	1802	1802
Terrain	1753	1753
Vegetation	1711	1711
Road	2444	2444
Other obstacle negative	0	0
Other obstacle positive	0	0
Total	3141	13805

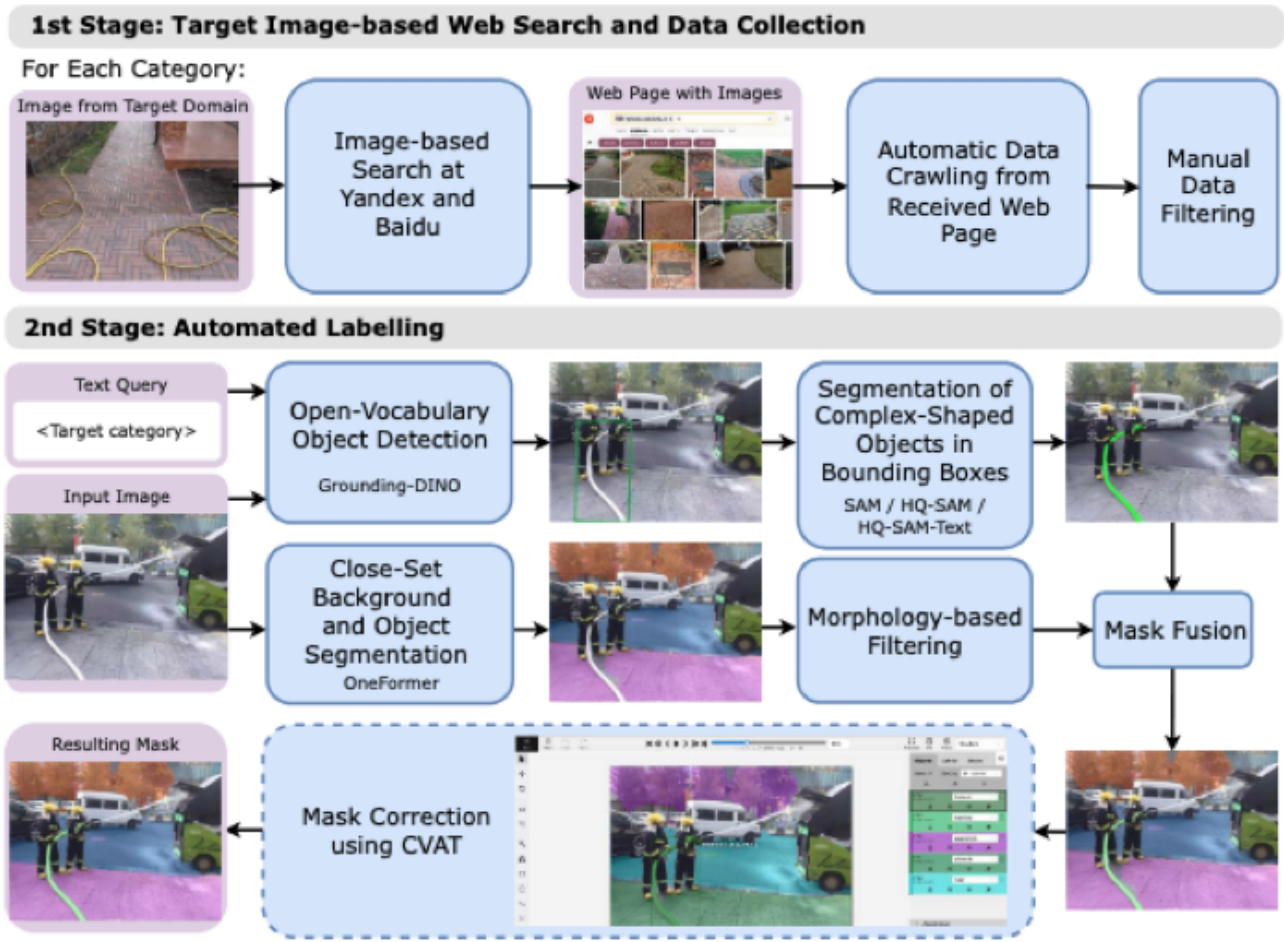

Датасет TAOMR

Эксперименты. Генерация объектов

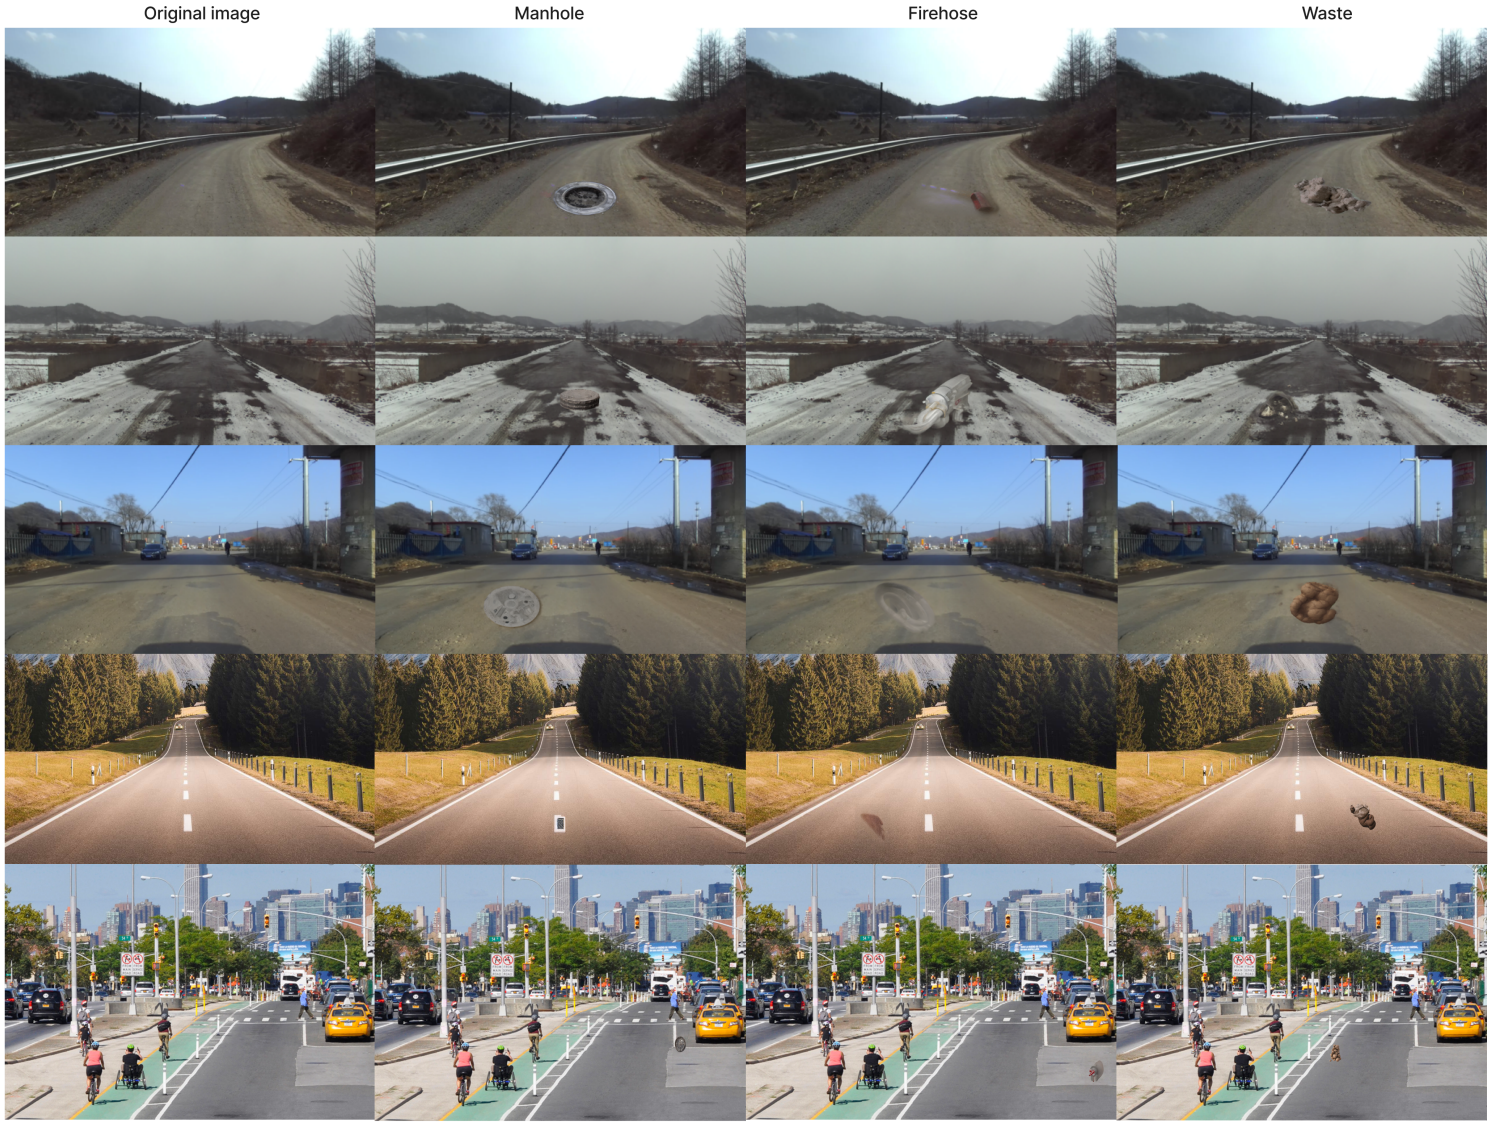

Использовались веса, обученные с помощью с MSE loss-функцией

Эксперименты. Loss-функция

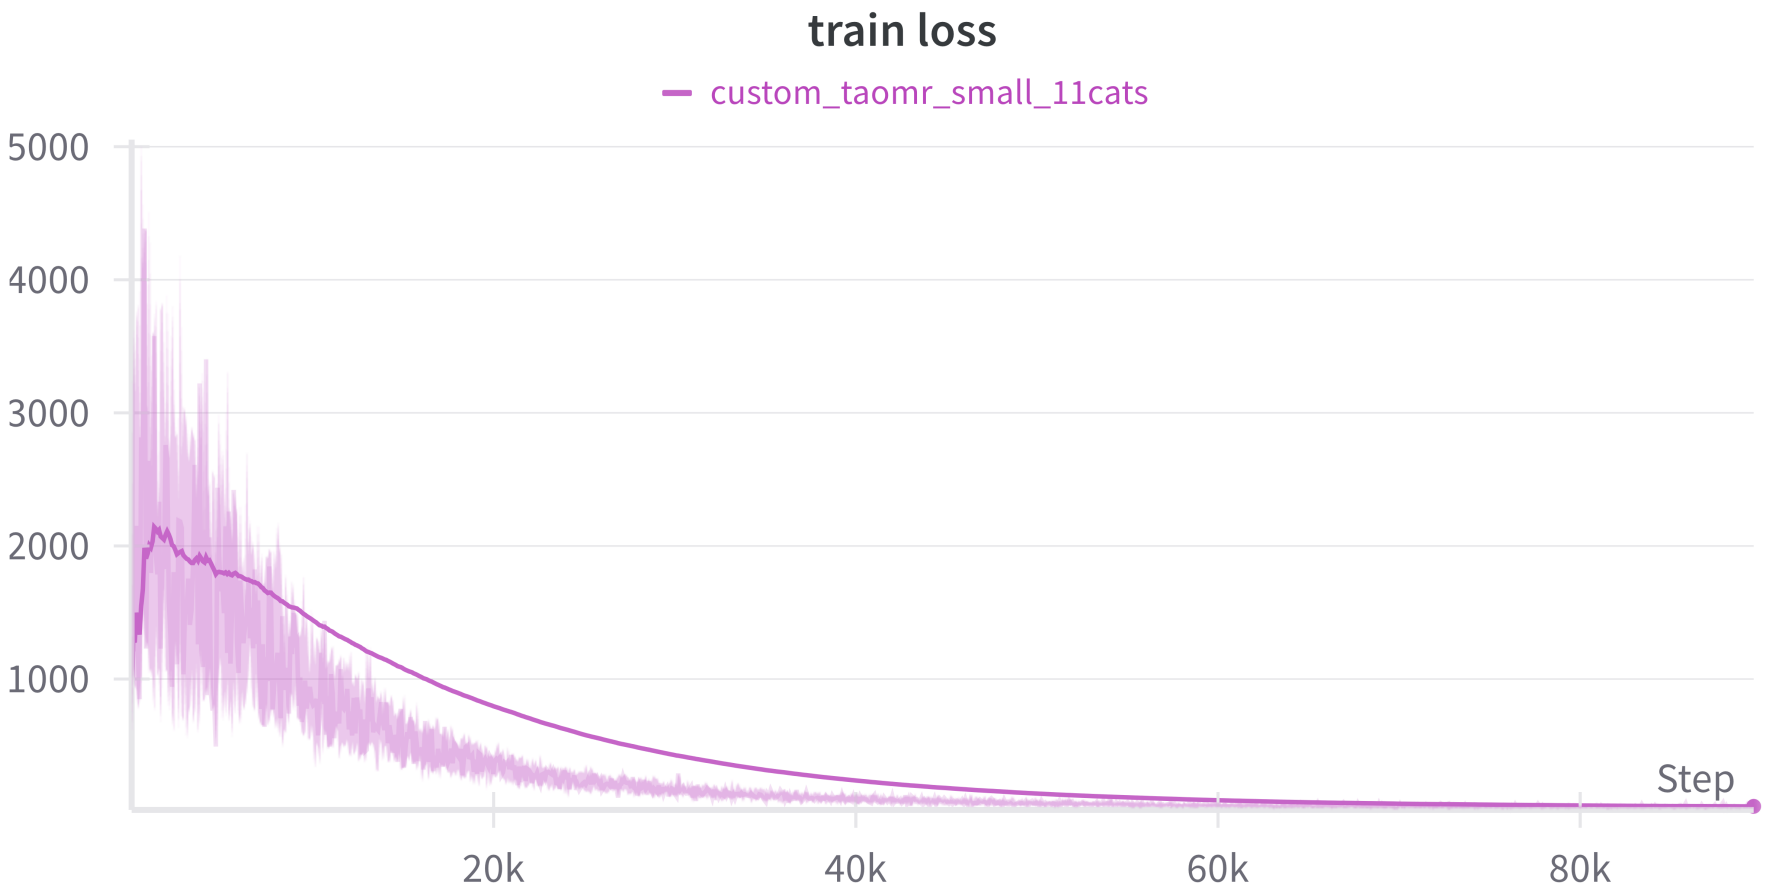

График новой функции потерь для 10 тысяч итераций

Эксперименты. Генерация объектов

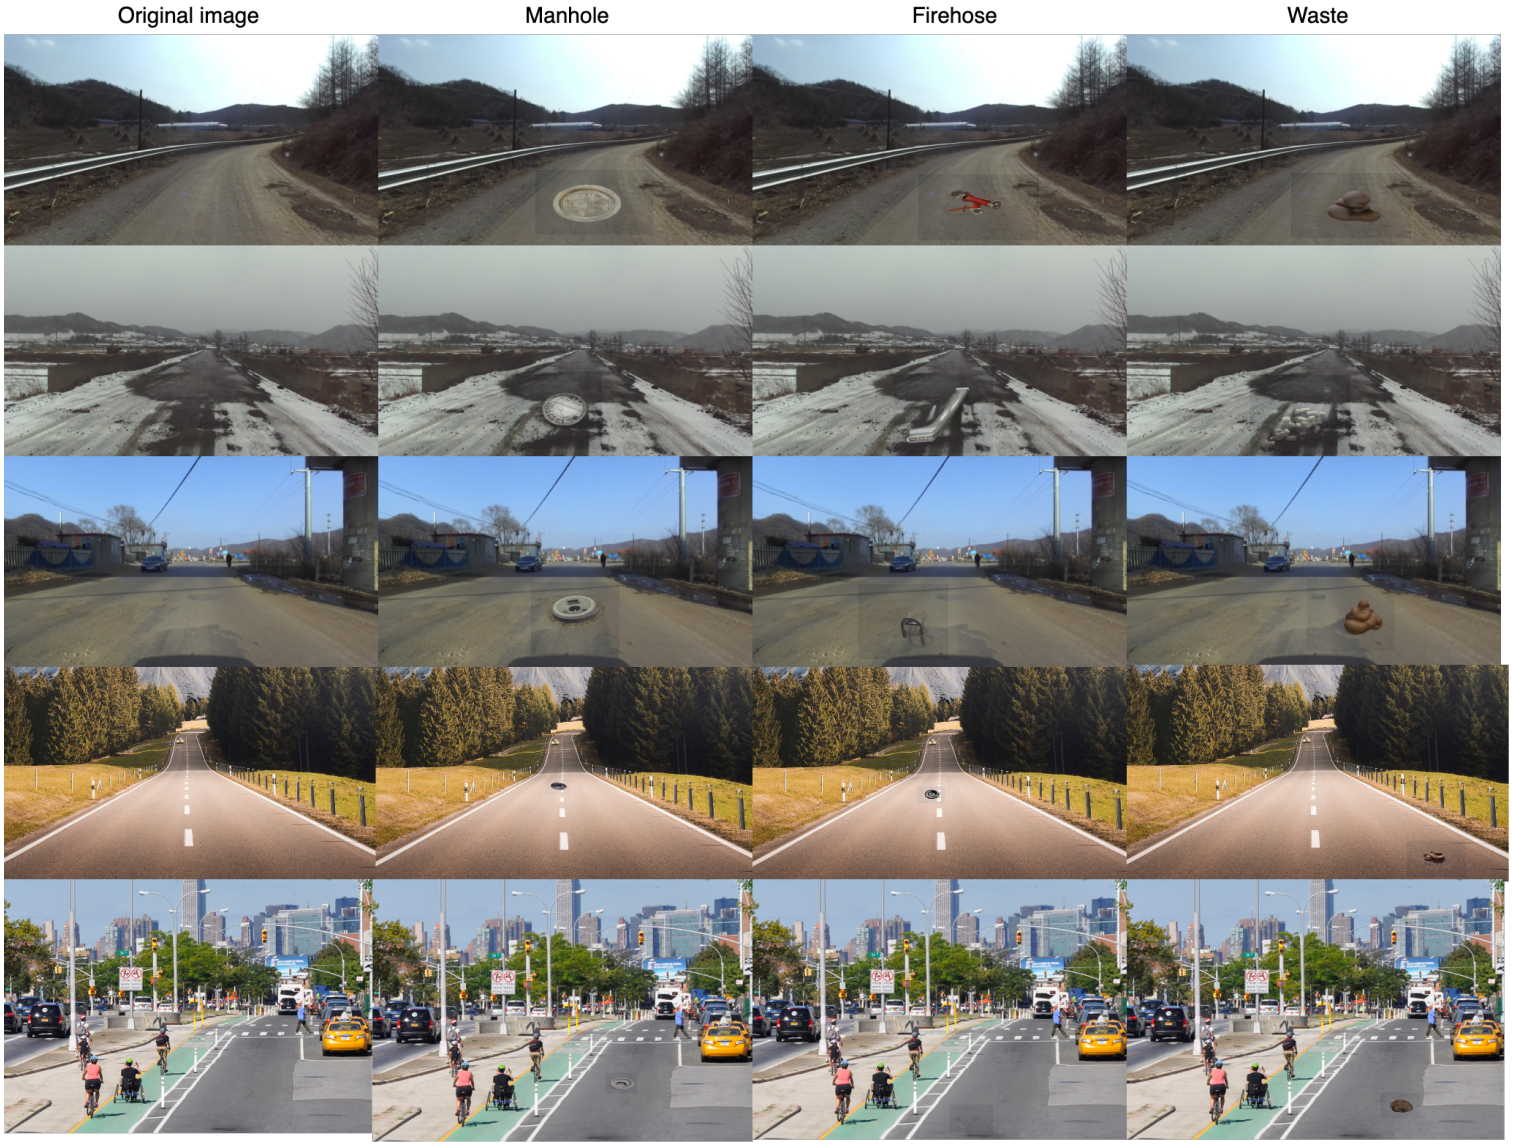

Использовались веса, обученные с помощью новой loss-функции

Сравнение моделей глубины

Название модели	Среднее время (с)	RMSE	AbsRel
Depth Anything	0.0380	9.1094	7.1462
Depth Anything V2	0.0384	8.9629	7.1368
MariGold	0.4283	10.4906	9.7801
DPT	0.0689	10.3837	6.9439

$$\text{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(z_i - \hat{z}_i)^2}, \quad \text{AbsRel} = \frac{1}{N}\sum_{i=1}^{N}\frac{|z_i - \hat{z}_i|}{z_i}$$

где z_i — истинное значение глубины, $\hat{z}_i$ — предсказанное значение.

Эксперименты. Использование глубины



Результаты экспериментов с использованием весов Depth Anything V2 на датасете INSTSnowRoadDetection

Эксперименты. Синтетический датасет

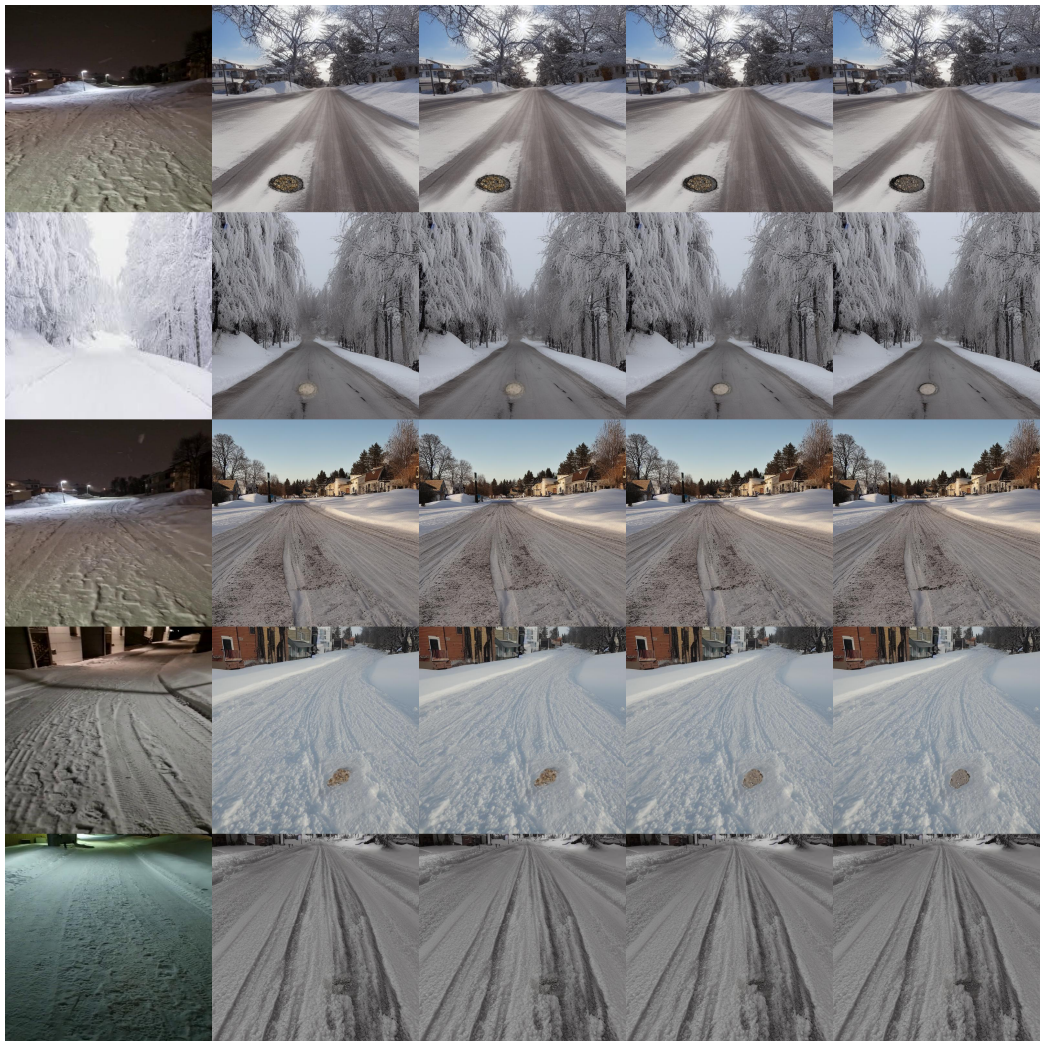

Результаты генерации синтетического датасета с использованием в Depth Anything V2 и Stable Diffusion 1.5

Выводы

- Новая loss-функция применима, но нужна доработка (подбор гиперпараметров)
- Генерация сцен в связи с генерацией объектов позволяет сгенерировать множество новых данных в нужном домене

Заключение

Были осуществлены следующие этапы:

- Реализация новой loss-функции
- Реализация пайплайна генерации полностью синтетического датасета

Дальнейшие исследования:

- Отлаживание обучения с использованием новой loss-функции
- Автоматизация пайплайна генерации синтетического датасета

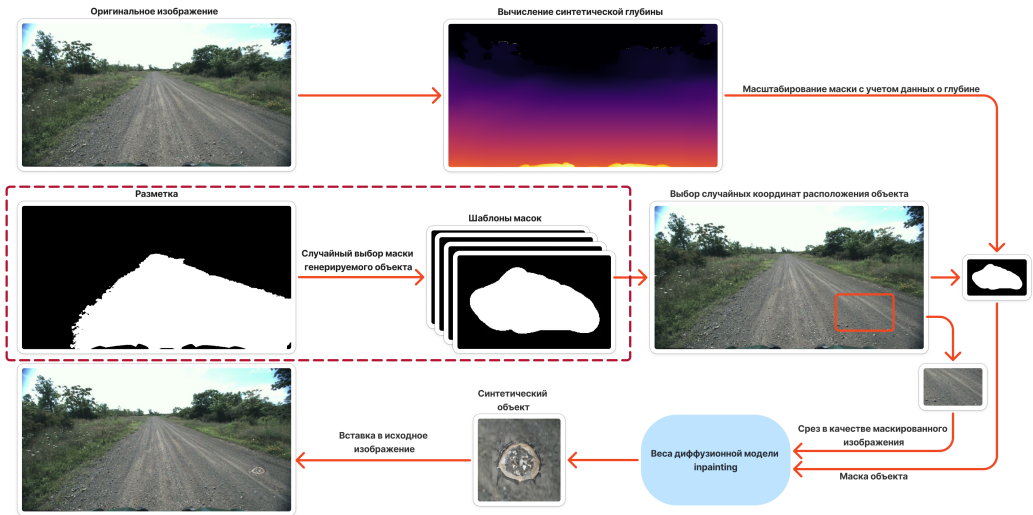

Спасибо за внимание!

izmesteva.ua@phystech.edu