

Создание персонализированных генераций изображений

Казистова Кристина Михайловна


Московский физико-технический институт

Курс: Научный трек Иннпрака ФПМИ/Группа Б05-124


Эксперт: Филатов Андрей Викторович

2024

Примеры генерации изображений




Latent Diffusion models



Основные этапы:


- ▶ Энкодер
- ▶ Скрытая диффузия
- ▶ Декодер

DreamBooth




- ▶ Принимает на вход несколько изображений одного объекта вместе с соответствующим названием класса
- ▶ Возвращает специальный токен, идентифицирующий объект
- ▶ Токен встраивается в текстовую подсказку, по которой генерируется желаемое изображение

IP-Adapter



- ▶ Энкодер для извлечения признаков изображения
- ▶ Адаптированные модули с механизмом перекрестного внимания

Наш метод



На вход подается несколько изображений вместо одного, каждому изображению соответствует своя текстовая подсказка. Ко входным изображениям применяется агрегирующая функция.

Процедура обучения: на каждом шаге из множества входных изображений случайно выбирается одно, удаляется из рассмотрения, и модель учится восстанавливать выброшенное изображение по его текстовому описанию и оставшимся картинкам.

Датасет

CelebA — набор данных по атрибутам лиц, содержащий более 200 тыс. изображений знаменитостей, каждое из которых снабжено 40 аннотациями к атрибутам.

Sample Images

Eyeglasses



Wearing Hat




Bangs



Wavy Hair



Pointy Nose



Mustache



Oval Face



Smiling



Постановка задачи

Определим датасет как $X_0 = \{(x_i, t_i) : i = 1, \dots, n\}$, где x_i — входное изображение, t_i — соответствующая ему текстовая подсказка.

Рассматривается модель из класса диффузионных моделей. На этапе обучения на каждом шаге из датасета X_0 удаляется изображение $x_j, j \sim \mathcal{U}\{1, \dots, n\}$.

Определим функцию потерь:

$$\mathcal{L} = \mathbb{E}_{X_0 \setminus \{x_j\}, \epsilon, c_t, c_i \setminus \{c_j\}, t} \|\epsilon - \epsilon_\theta(X_t, c_t, c_i \setminus \{c_j\}, t)\|^2,$$

где G — агрегирующая функция, применяемая ко входным данным; c_t — текстовые признаки; c_i — признаки изображений; c_j — признаки удаленного изображения; $t \in [0, T]$ — временной шаг диффузионного процесса; $X_t = \alpha_t G(X_0 \setminus \{x_j\}) + \sigma_t \epsilon$ — зашумленные данные на шаге t ; α_t, σ_t — предопределенные функции от t , определяющие диффузионный процесс; ϵ_θ — цель обучения модели диффузии.

Решается следующая оптимизационная задача:

$$\theta^* = \arg \min_{\theta} \mathcal{L}(G(X_0 \setminus \{x_j\}), \epsilon, c_t, c_i \setminus \{c_j\}, t, x_t, \epsilon_\theta),$$

Постановка задачи

Frechet Inception Distance (FID), Inception Score (IS) — это метрики, которые используются для оценки качества генерации изображений
Формула для FID:

$$FID = \|\mu_p - \mu_q\|^2 + Tr(\Sigma_p + \Sigma_q - 2(\Sigma_p \Sigma_q)^{1/2}),$$

где μ_p и μ_q — средние значения признаков в реальных и сгенерированных изображениях соответственно, Σ_p и Σ_q — ковариационные матрицы для распределений признаков в реальных и сгенерированных изображениях соответственно.

Формула для IS:

$$IS(x) = \exp(\mathbb{E}_x [D_{KL}(p(y|x)||p(y))]),$$

где D_{KL} — дивергенция Кульбака-Лейблера для двух распределений $p(y|x)$ — вероятность класса y для изображения x и $p(y)$ — равномерное распределение на множестве классов, \mathbb{E}_x — математическое ожидание по всем изображениям x .

Вычислительный эксперимент

- ▶ Написаны скрипты для запуска DreamBooth и IP-Adapter

План работы

- ▶ Подобрать агрегирующие функции
- ▶ Подобрать метрики идентичности и метрики разнообразия
- ▶ Реализовать наш метод с разными агрегирующими функциями
- ▶ Сравнить IP-Adapter и DreamBooth с нашей моделью, используя значения вышеупомянутых метрик