

---

# Создание персонализированных генераций изображений

---

К. М. Казистова  
ФПМИ  
МФТИ  
Долгопрудный  
kazistova.km@phystech.edu

И. Д. Степанов  
ФПМИ  
МФТИ  
Долгопрудный  
iliatut94@gmail.com

А. В. Филатов  
Сколковский Институт Технологий  
Москва  
filatovandreiv@gmail.com

УДК 004.855,004.853

## 1 Тезис

Существующие модели способны генерировать разнообразные изображения по текстовым описаниям с высокой точностью. Однако, в процессе работы с моделями генерации изображений возникают определенные проблемы, одной из которых является недостаточное соответствие сгенерированных изображений и исходным текстовым подсказкам. Наша задача заключается в повышении качества визуальных представлений за счет большего количества графических подсказок. В работе рассматриваются методы, которые позволяют решить вышеупомянутые проблемы, и затем сравниваются между собой. Все описанные далее подходы основаны на применении Stable Diffusion(2).

Первый представленный метод — это DreamBooth(3). Он принимает на вход несколько изображений одного объекта вместе с соответствующим названием класса и возвращает специальный токен, идентифицирующий объект, который затем встраивается в текстовую подсказку, по которой генерируется желаемое изображение. Проблемы данного метода заключаются в слабой адаптивности, отсутствии обобщения и необходимости обучать всю диффузионную модель.

Второй метод — это IP-Adapter(1). Он состоит из двух частей: энкодера для извлечения признаков изображения, текста и адаптированных модулей с механизмом перекрестного внимания. Метод принимает на вход только одно изображение объекта. Однако одной картинки может быть мало, для того чтобы модель могла уловить все необходимые зависимости.

В работе предлагается третий метод, представляющий собой модификацию IP-Adapter. На вход подаются несколько изображений вместо одного, причем каждому изображению соответствует своя текстовая подсказка. В процессе обучения модели одно изображение удаляется равновероятно, и модель учится восстанавливать это удаленное изображение, опираясь на текстовое описание и другие имеющиеся изображения. К этим имеющимся изображениям применяется агрегирующая функция. За счет подачи нескольких изображений добиваемся лучшей передачи идентичности. Рассмотренные методы сравниваются между собой по метрикам качества генерации и разнообразия, метрикам идентичности. Исследование проводится на выборке из датасета LFW Deep Funneled(5) — датасете изображений знаменитостей в высоком разрешении.

Определим датасет как  $\mathcal{D} = \{(\mathbf{x}_i, \tau_i) : i = 1, \dots, n\}$ ,  $\mathbf{x}_i$  — латентное представление изображения,  $\tau_i$  — текстовая подсказка. На этапе обучения на каждом шаге из  $\mathcal{D}$  удаляется изображение  $\mathbf{x}_j, j \sim \mathcal{U}\{1, \dots, n\}$  и решается следующая оптимизационная задача:

$$\epsilon_{\theta}^* = \arg \min_{\epsilon_{\theta}} \mathcal{L}(\epsilon, \epsilon_{\theta}), \quad (1)$$

Определим функцию потерь:

$$\mathcal{L}(\epsilon, \epsilon_{\theta}) = \mathbb{E}_{\epsilon \sim N(0, I), \mathbf{c}_{\tau}, G(\mathbf{c}_i \setminus \{\mathbf{c}^j\}), t, \mathbf{x}_t^j} \|\epsilon - \epsilon_{\theta}(\mathbf{c}_{\tau}, G(\mathbf{c}_i \setminus \{\mathbf{c}^j\}), t, \mathbf{x}_t^j)\|^2, \quad (2)$$

где  $G$  — агрегирующая функция, применяемая ко входным данным;  $\mathbf{c}_{\tau}$  — текстовые признаки удаленного изображения;  $\mathbf{c}_i$  — признаки изображений;  $\mathbf{c}^j$  — признаки удаленного изображения;  $t \in [0, T]$  —

временной шаг диффузионного процесса;  $\mathbf{x}_t^j = \alpha_t \mathbf{x}^j + \sigma_t \epsilon$  — зашумленные данные удаленного изображения на шаге  $t$ ;  $\alpha_t, \sigma_t$  — предопределенные функции от  $t$ , определяющие диффузионный процесс;  $\epsilon_\theta$  — цель обучения модели диффузии.

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

$$FID = \|\mu_p - \mu_q\|^2 + Tr(\Sigma_p + \Sigma_q - 2(\Sigma_p \Sigma_q)^{1/2}) \quad (3)$$

где  $\mu_p$  и  $\mu_q$  — средние значения признаков в реальных и сгенерированных изображениях соответственно,  $\Sigma_p$  и  $\Sigma_q$  — ковариационные матрицы для распределений признаков на реальных и сгенерированных изображениях соответственно.

$$IS(x) = \exp(\mathbb{E}_x [D_{KL}(p(y|x)||p(y))]) \quad (4)$$

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  $x$ .

### 1.1 IP-AdapterMAX и IP-AdapterAVG

Данная модификация метода IP-Adapter включает в себя обработку нескольких изображений, к которым применяются агрегирующие функции MAXpooling или AVGpooling для их латентных представлений. На вход подаются изображения людей, вычисляются эмбединги данных изображений, после чего к эмбедингам применяются упомянутые ранее функции агрегации. В данном случае полученное латентное представление интегрируется в полностью предобученную модель IP-Adapter. Вычисление метрик производится на всем датасете.

### 1.2 IP-AdapterSelf-Attention

Предложенная модификация метода IP-Adapter включает в себя обработку нескольких изображений, к которым применяется алгоритм Self-Attention(4) для их латентных представлений. Исходный датасет разделяется на тренировочную и тестовую выборки в соотношении 2 : 1. Тренировочная выборка содержит набор персон, каждая из которых обладает 10 изображениями, к каждому из которых прилагается текстовая подсказка. Обучение происходит на 9 изображениях: в ходе обучения осуществляется попытка предсказать 10-е изображение, используя текстовую подсказку и предварительно обработанные эмбединги 9 изображений. Выбор удаленного изображения осуществляется равновероятно.

---

#### Algorithm 1 Self-Attention

---

```

procedure Self-Attention( $\mathbf{x}$ )
   $\mathbf{Q} \leftarrow \mathbf{x} \cdot \mathbf{W}_q$ 
   $\mathbf{K} \leftarrow \mathbf{x} \cdot \mathbf{W}_k$ 
   $\mathbf{V} \leftarrow \mathbf{x} \cdot \mathbf{W}_v$ 
   $\mathbf{Z} \leftarrow softmax\left(\frac{\mathbf{Q} \cdot \mathbf{K}^T}{\sqrt{d_k}}\right) \cdot \mathbf{V}$ 
  return  $\mathbf{Z} \cdot \mathbf{W}_{out}$ 
end procedure

```

---

После завершения этапа модуля Self-Attention последуют модули IP-Adapter без изменений. В данном случае обучаются модули Self-Attention, Linear и Cross-Attention. Поскольку модификация Self-Attention обучается на 9 изображениях, то если от пользователя поступит большее или меньшее число изображений, в первом случае лишние изображения просто удаляются, а во втором выполняется процедура бутстрапа до достижения нужного количества картинок.

Таблица 1: Результаты эксперимента

| Метод                    | IS    | FID   |
|--------------------------|-------|-------|
| IP-Adapter               | 15.37 | 8.92  |
| DreamBooth               | 17.64 | 9.61  |
| IP-AdapterMAX            | 14.12 | 10.10 |
| IP-AdapterAVG            | -     | -     |
| IP-AdapterSelf-Attention | -     | -     |

## Список литературы

- [1] "IP-Adapter"<https://arxiv.org/pdf/2308.06721.pdf>.
- [2] "Latent Stable Diffusion"<https://arxiv.org/abs/2112.10752.pdf>.
- [3] "DreamBooth"<https://arxiv.org/pdf/2208.12242.pdf>.
- [4] "Attention"<https://arxiv.org/pdf/1706.03762.pdf>.
- [5] "Dataset"<https://vis-www.cs.umass.edu/lfw/>.