

Direct Preference Optimization with Diffusion Models

2024.5.31 DMQA Open Seminar

DMQA 장건희

Introduction



❖ 장건희 (Geonhui Jang)

- 고려대학교 산업경영공학과 석사 과정 (2023.03 ~ Present)
- Data Mining & Quality Analytics Lab (김성범 교수님)

❖ Research Interests

- Generative Models
- Computer Vision, Diffusion Models
- LLM, Multimodal Models

❖ Contact

- csleivear1@korea.ac.kr

Preliminary

❖ RLHF (Reinforcement Learning from Human Feedback)

- 인간 선호도 데이터셋을 바탕으로 모델을 튜닝하는 방식

❖ DPO (Direct Preference Optimization)

- RLHF 방식에서 reward model 학습 없이 인간 선호도 데이터셋만을 이용해 LLM (Large Language Models)을 바로 튜닝하는 방식

※ LLM을 인간 선호도 (human preference) 데이터셋으로 학습하는 이유?

- 사용자의 입력에 대해 안전하고 유용한 (Helpful, Honest, Harmless) 답변을 주는 LM을 만들기 위해
- 그 외에 특정 도메인의 전문 지식으로 LLM을 fine-tuning 하고자 하는 경우 등

L = (폭력성/선정성 없는 텍스트를
생성하도록 하는 손실함수)

VS.



→ 인간 선호 자체를 모델링할 수 있는 손실함수는 만들기 매우 어려움



따라서 인간이 선호하는 방향으로 output이 생성될 수 있도록
인간 선호도 데이터셋을 통해 모델을 학습

1. 위 손실함수 L 을 이용해 학습

2. (a)를 생성하고 (b)를 생성하지 않도록 학습

Preliminary

❖ RLHF (Reinforcement Learning from Human Feedback)

- 인간 선호도 데이터셋을 바탕으로 모델을 튜닝하는 방식

❖ DPO (Direct Preference Optimization)

- RLHF 방식에서 reward model 학습 없이 인간 선호도 데이터셋만을 이용해 LLM (Large Language Models)을 바로 튜닝하는 방식

❖ Diffusion-DPO

- 디퓨전 모델 fine-tuning 시 L_{simple} 대신 DPO loss를 이용한 새로운 loss로 튜닝

❖ DCO (Direct Consistency Optimization)

- Personalization 시 L_{simple} 대신 DPO loss를 이용한 새로운 loss로 튜닝



→ LM 분야에서 인간이 선호하는 텍스트를 생성하도록 학습한 것과 같이
디퓨전 분야에서도 인간이 선호하는 이미지를 생성하도록 학습하고자 함

요약

2017.6

강화학습 기반으로 인간 선호를 학습하는 RLHF



2023.5

RLHF에서 강화학습 부분을 제거한 DPO



2023.11 & 2024.2

DPO를 디퓨전 모델에 적용한 Diffusion-DPO와 DCO

Preliminary

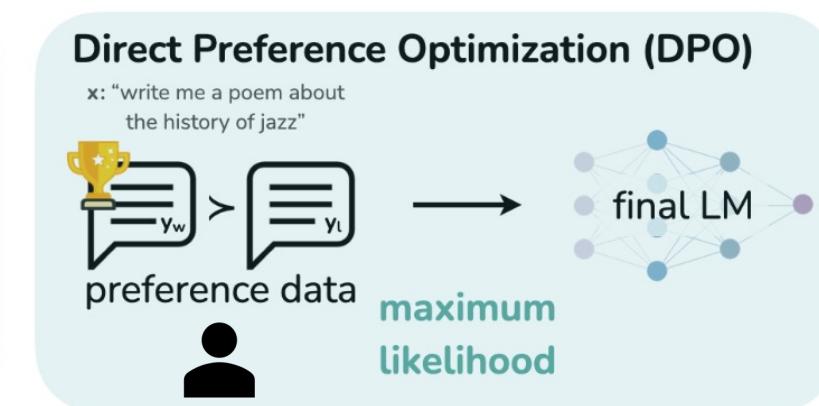
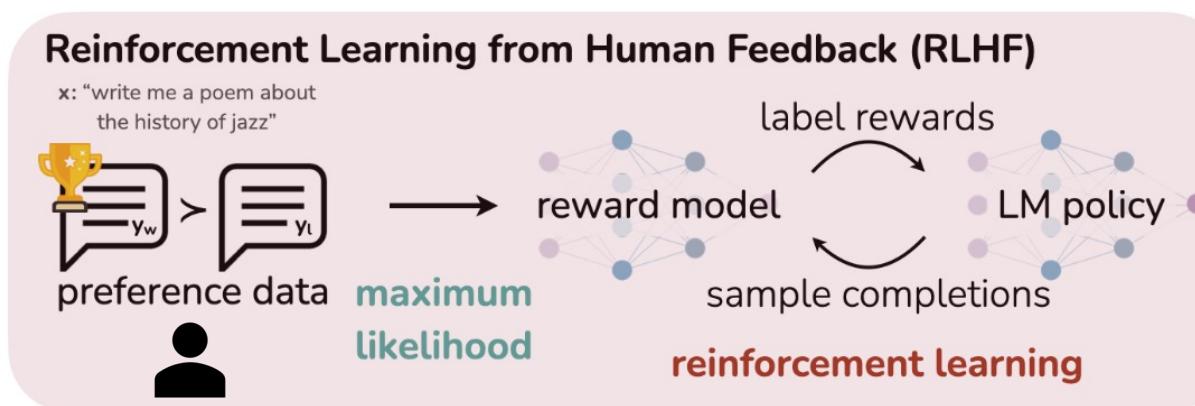
RLHF와 DPO

❖ RLHF (Reinforcement Learning from Human Feedback)

- 인간 선호도 데이터셋을 바탕으로 모델을 튜닝하는 방식
- Supervised fine-tuning – Reward modeling – Fine-tuning with RM 세 단계로 구성
- ChatGPT, InstructGPT, LLaMA2 등 여러 LLM fine-tuning에 사용

❖ DPO (Direct Preference Optimization)

- RLHF 방식에서 reward model 학습 없이 인간 선호도 데이터만을 이용해 LLM (Large Language Models)을 바로 튜닝하는 방식
- RLHF 목적식의 최적해를 LLM 목적 함수에 통합



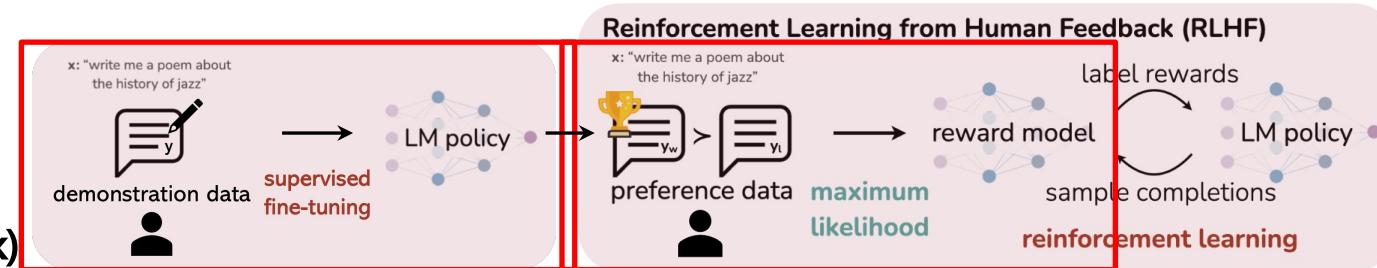
<RLHF와 DPO 비교>

Preliminary

RLHF와 DPO

❖ RLHF (Reinforcement Learning from Human Feedback)

- Supervised fine-tuning – Reward modeling – Fine-tuning with RM 세 단계로 구성



<Bradley-Terry Model (1952)>

$$p^*(y_1 \succ y_2 | x) = \frac{\exp(r^*(x, y_1))}{\exp(r^*(x, y_1)) + \exp(r^*(x, y_2))}$$

→ Pair 데이터 사이 선호도에 대한 확률 분포를 정의 (선호 확률이 optimal reward와 비례)

[Step 1] Supervised fine-tuning

- Human labeler가 Input x 에 대해 desired output y 를 작성 → 이 demonstration data로 LLM fine-tuning

[Step 2] Reward modeling

- Fine-tuned LLM이 Input x 에 대해 두 개의 model output 생성 → human labeler가 이 두 output 중 더 선호하는 답변 선택
- Human preference dataset $\{(x, y_w, y_l)^i\}_{i=1}^N$ 으로 reward model r_ϕ 학습 → 학습 후 reward model은 desirable output 일수록 높은 점수 반환

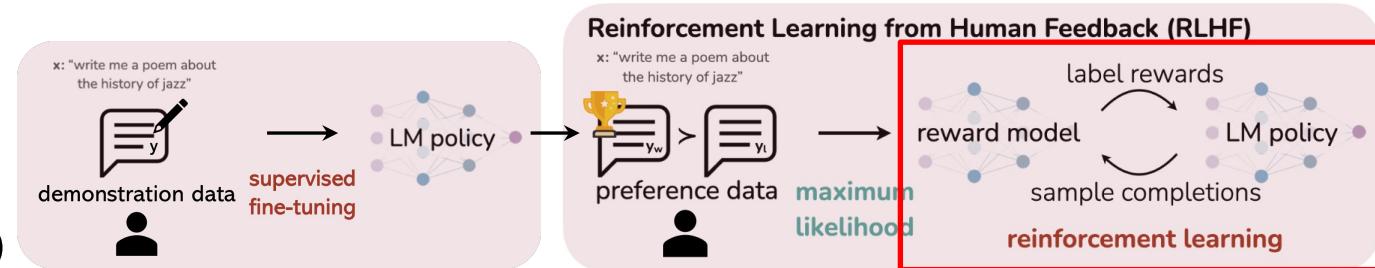
$$\mathcal{L}_R(r_\phi, \mathcal{D}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} [\log \sigma(r_\phi(x, y_w) - r_\phi(x, y_l))]$$

Preliminary

RLHF와 DPO

❖ RLHF (Reinforcement Learning from Human Feedback)

- Supervised fine-tuning – Reward modeling – Fine-tuning with RM 세 단계로 구성



[Step 1] Supervised fine-tuning

- Human labeler가 Input x 에 대해 desired output y 를 작성 → 이 demonstration data로 LLM fine-tuning

[Step 2] Reward modeling

- Fine-tuned LLM이 Input x 에 대해 두 개의 model output 생성 → human labeler가 이 두 output 중 더 선호하는 답변 선택
- Human preference dataset $\{(x, y_w, y_l)^i\}_{i=1}^N$ 으로 reward model r_ϕ 학습 → 학습 후 reward model은 desirable output일수록 높은 점수 반환

$$\mathcal{L}_R(r_\phi, \mathcal{D}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} [\log \sigma(r_\phi(x, y_w) - r_\phi(x, y_l))]$$

[Step 3] Fine-tuning with RM

- Reward가 최대화되도록 LLM π_θ 를 fine-tuning함. 여기에 기존 모델 분포 π_{ref} 와 너무 달라지지 않도록 KL divergence 제약 추가
- 일반적으로 강화학습 방식 중 하나인 PPO (Proximal Policy Optimization)을 통해 최적화

$$\max_{\pi_\theta} \mathbb{E}_{x \sim \mathcal{D}, y \sim \pi_\theta(y|x)} [r_\phi(x, y)] - \beta \mathbb{D}_{\text{KL}} [\pi_\theta(y | x) || \pi_{\text{ref}}(y | x)]$$

<Bradley-Terry Model (1952)>

$$p^*(y_1 \succ y_2 | x) = \frac{\exp(r^*(x, y_1))}{\exp(r^*(x, y_1)) + \exp(r^*(x, y_2))}$$

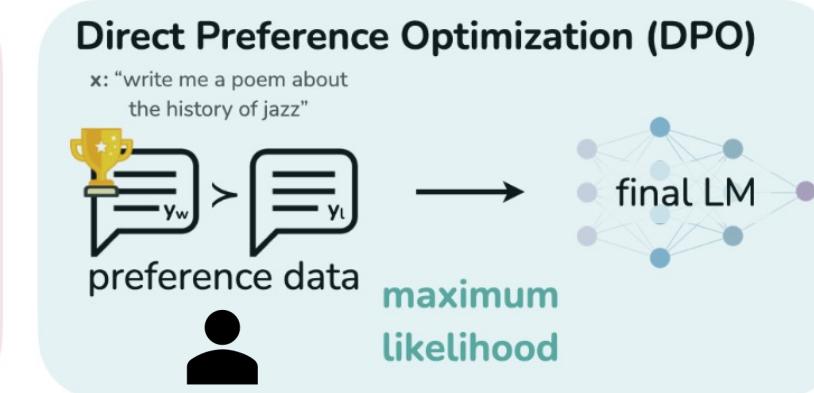
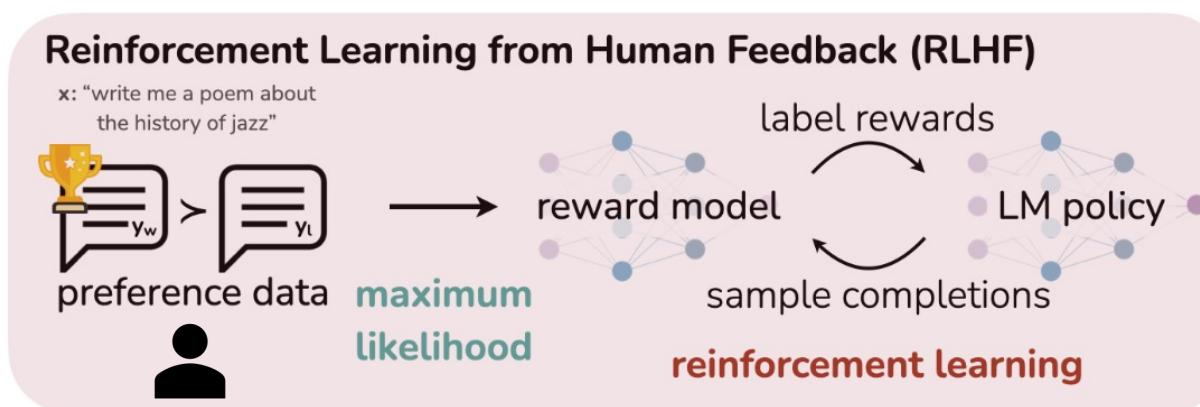
→ Pair 데이터 사이 선호도에 대한 확률 분포를 정의 (선호 확률이 optimal reward와 비례)

Preliminary

RLHF와 DPO

❖ DPO (Direct Preference Optimization)

- RLHF 방식에서 **reward model 학습 없이 인간 선호도 데이터셋만을 이용해 LLM을 바로 튜닝하는 방식**
- **Why?** (1) Reward model, critic model 등 강화학습을 위해 추가 모델 학습 필요
(2) LLM이 reward model 및 critic model과 상호작용할 때 학습 불안정성 + reward는 높지만 부자연스러운 문장을 생성하는 mode collapse
- **How?** → RLHF 목적식의 최적해를 LLM 목적 함수에 통합
- Reward model은 없어졌지만 reward 메커니즘을 LLM loss에 담음
→ “DPO를 통해 언어모델은 implicit하게 human preference를 이해하는 reward model로서 기능할 수 있음”



<RLHF와 DPO 비교>

Preliminary

RLHF와 DPO

❖ DPO (Direct Preference Optimization)

- RLHF 목적식의 최적해를 구함

$$\max_{\pi} \mathbb{E}_{x \sim \mathcal{D}, y \sim \pi} [r(x, y)] - \beta \mathbb{D}_{\text{KL}} [\pi(y|x) \parallel \pi_{\text{ref}}(y|x)]$$

$$= \max_{\pi} \mathbb{E}_{x \sim \mathcal{D}} \mathbb{E}_{y \sim \pi(y|x)} \left[r(x, y) - \beta \log \frac{\pi(y|x)}{\pi_{\text{ref}}(y|x)} \right]$$

$$= \min_{\pi} \mathbb{E}_{x \sim \mathcal{D}} \mathbb{E}_{y \sim \pi(y|x)} \left[\log \frac{\pi(y|x)}{\pi_{\text{ref}}(y|x)} - \frac{1}{\beta} r(x, y) \right]$$

$$= \min_{\pi} \mathbb{E}_{x \sim \mathcal{D}} \mathbb{E}_{y \sim \pi(y|x)} \left[\log \frac{\pi(y|x)}{\frac{1}{Z(x)} \pi_{\text{ref}}(y|x) \exp \left(\frac{1}{\beta} r(x, y) \right)} - \log Z(x) \right]$$

$$= \min_{\pi} \mathbb{E}_{x \sim \mathcal{D}} [\mathbb{D}_{\text{KL}} (\pi(y|x) \parallel \pi^*(y|x)) - \log Z(x)]$$

$$\pi^*(y|x) = \frac{1}{Z(x)} \pi_{\text{ref}}(y|x) \exp \left(\frac{1}{\beta} r(x, y) \right)$$

$$\therefore \pi(y|x) = \pi^*(y|x) = \frac{1}{Z(x)} \pi_{\text{ref}}(y|x) \exp \left(\frac{1}{\beta} r(x, y) \right) \quad \text{where } Z(x) = \sum_y \pi_{\text{ref}}(y|x) \exp \left(\frac{1}{\beta} r(x, y) \right)$$

Preliminary

RLHF와 DPO

- $\pi(y|x)$: Human preference data \mathcal{D} 에 대해 fine-tuning되는 LLM
- $\pi_{\text{ref}}(y|x)$: RLHF Step 1에서 supervised fine-tuned된 LLM
- $r(x, y)$: Human preference data로 학습된 reward model

❖ DPO (Direct Preference Optimization)

- Reward model formulation을 LLM output에 대한 수식으로 바꾸고 이를 이용해 목적식 재정의

$$\pi^*(y|x) = \frac{1}{Z(x)} \pi_{\text{ref}}(y|x) \exp\left(\frac{1}{\beta} r(x, y)\right) \longrightarrow r(x, y) = \beta \log \frac{\pi^*(y|x)}{\pi_{\text{ref}}(y|x)} + \beta \log Z(x)$$

- Reward model을 사용하지 않으면서 Bradley-Terry Model (선호도 확률분포)에 부합하는 LLM optimization 목적식을 만듦
- 최종적으로 human preference dataset \mathcal{D} 와 reference LLM model π_{ref} 만으로 모델을 학습할 수 있음

$$\begin{aligned} & p^*(y_1 \succ y_2 | x) \\ & \quad \text{Reward model output 수식을} \\ &= \frac{\exp(r^*(x, y_1))}{\exp(r^*(x, y_1)) + \exp(r^*(x, y_2))} \\ & \quad \downarrow \quad \text{LLM output 수식으로 대체} \\ &= \frac{1}{1 + \exp\left(\beta \log \frac{\pi^*(y_1|x)}{\pi_{\text{ref}}(y_2|x)} - \beta \log \frac{\pi^*(y_2|x)}{\pi_{\text{ref}}(y_1|x)}\right)} \end{aligned}$$

<선호도 확률분포 재정의>

$$\begin{aligned} & \mathcal{L}_R(r_\phi, \mathcal{D}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} [\log \sigma(r_\phi(x, y_w) - r_\phi(x, y_l))] \\ & \quad \downarrow \quad \text{LLM output 수식으로 대체} \\ & \mathcal{L}_{\text{DPO}}(\pi_\theta; \pi_{\text{ref}}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} \left[\log \sigma \left(\beta \log \frac{\pi_\theta(y_w | x)}{\pi_{\text{ref}}(y_w | x)} - \beta \log \frac{\pi_\theta(y_l | x)}{\pi_{\text{ref}}(y_l | x)} \right) \right] \end{aligned}$$

<LLM 손실함수 재정의>

Preliminary

RLHF와 DPO

- $\pi_\theta(y|x)$: fine-tuning되는 LLM
- $\pi_{\text{ref}}(y|x)$: RLHF Step 1에서 supervised fine-tuned된 LLM
- $r(x, y)$: Human preference data로 학습된 reward model

❖ DPO (Direct Preference Optimization)

- Gradient analysis of DPO loss

$$\mathcal{L}_{\text{DPO}}(\pi_\theta; \pi_{\text{ref}}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} \left[\log \sigma \left(\beta \log \frac{\pi_\theta(y_w | x)}{\pi_{\text{ref}}(y_w | x)} - \beta \log \frac{\pi_\theta(y_l | x)}{\pi_{\text{ref}}(y_l | x)} \right) \right]$$

$$\nabla_\theta \mathcal{L}_{\text{DPO}}(\pi_\theta; \pi_{\text{ref}}) =$$

$$-\beta \mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} \left[\underbrace{\sigma(\hat{r}_\theta(x, y_l) - \hat{r}_\theta(x, y_w))}_{\text{higher weight when reward estimate is wrong}} \left[\underbrace{\nabla_\theta \log \pi(y_w | x)}_{\text{increase likelihood of } y_w} - \underbrace{\nabla_\theta \log \pi(y_l | x)}_{\text{decrease likelihood of } y_l} \right] \right]$$

where $\hat{r}_\theta(x, y) = \beta \log \frac{\pi_\theta(y|x)}{\pi_{\text{ref}}(y|x)}$
(=LLM으로 정의된 implicit reward estimate)

y_w (선호 응답)의 likelihood가 증가하도록 학습 y_l (선호하지 않는 응답)의 likelihood가 감소하도록 학습

Preliminary

RLHF와 DPO

DPO (Direct Preference Optimization)

- Gradient analysis of DPO loss

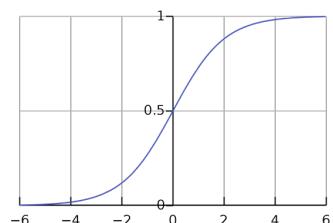
$$\mathcal{L}_{\text{DPO}}(\pi_\theta; \pi_{\text{ref}}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} \left[\log \sigma \left(\beta \log \frac{\pi_\theta(y_w | x)}{\pi_{\text{ref}}(y_w | x)} - \beta \log \frac{\pi_\theta(y_l | x)}{\pi_{\text{ref}}(y_l | x)} \right) \right]$$

$$\nabla_\theta \mathcal{L}_{\text{DPO}}(\pi_\theta; \pi_{\text{ref}}) =$$

$$-\beta \mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} \left[\underbrace{\sigma(\hat{r}_\theta(x, y_l) - \hat{r}_\theta(x, y_w))}_{\text{higher weight when reward estimate is wrong}} \left[\underbrace{\nabla_\theta \log \pi(y_w | x)}_{\text{increase likelihood of } y_w} - \underbrace{\nabla_\theta \log \pi(y_l | x)}_{\text{decrease likelihood of } y_l} \right] \right]$$

where $\hat{r}_\theta(x, y) = \beta \log \frac{\pi_\theta(y|x)}{\pi_{\text{ref}}(y|x)}$
(=LLM으로 정의된 implicit reward estimate)

y_w (선호 응답)의 likelihood가 증가하도록 학습 y_l (선호하지 않는 응답)의 likelihood가 감소하도록 학습



<Sigmoid 함수>

y_l (선호하지 않는 응답)의 reward estimate가 클수록,

y_w (선호 응답)의 reward estimate가 작을수록

(=모델이 잘못된 reward estimate를 반환할수록) 큰 가중치 부여

- $\pi_\theta(y|x)$: fine-tuning되는 LLM

- $\pi_{\text{ref}}(y|x)$: RLHF Step 1에서 supervised fine-tuned된 LLM

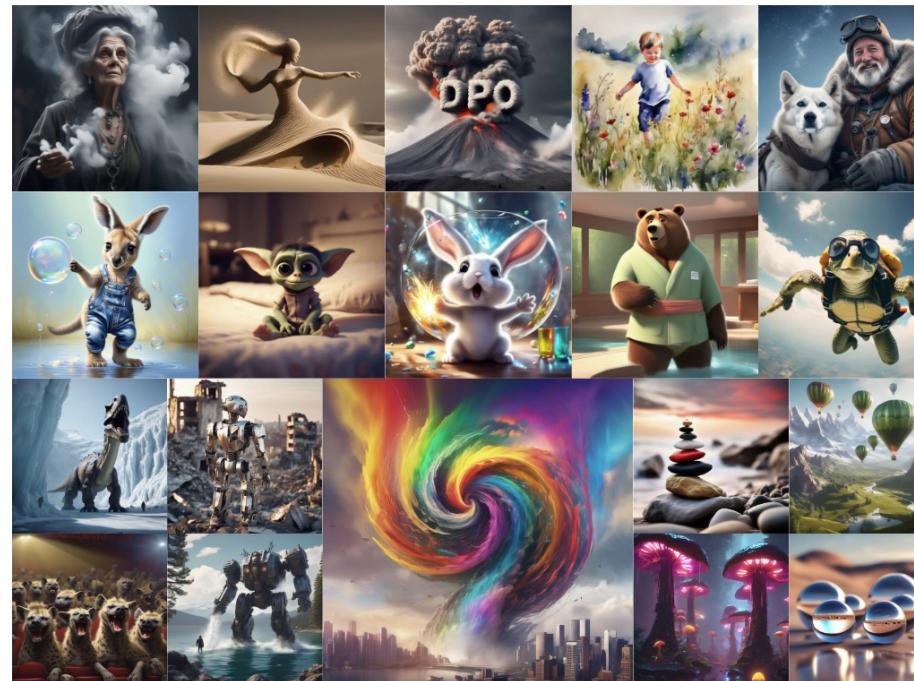
- $r(x, y)$: Human preference data로 학습된 reward model

Diffusion-DPO

DPO for Diffusion Models

❖ 디퓨전 모델에도 인간 선호도를 반영할 수 있는 DPO loss function을 적용하자

- **LLM:** {입력 프롬프트 x , 선호 답변 y_w , 선호하지 않는 답변 y_l }
- **디퓨전 모델:** {입력 샘플링 프롬프트 x , 선호 이미지 y_w , 선호하지 않는 이미지 y_l }
- 단순히 이미지에 추가된 노이즈를 예측하는 것만 학습하지 않고, 인간이 선호하는 이미지를 더 잘 생성하도록 가이드를 주자



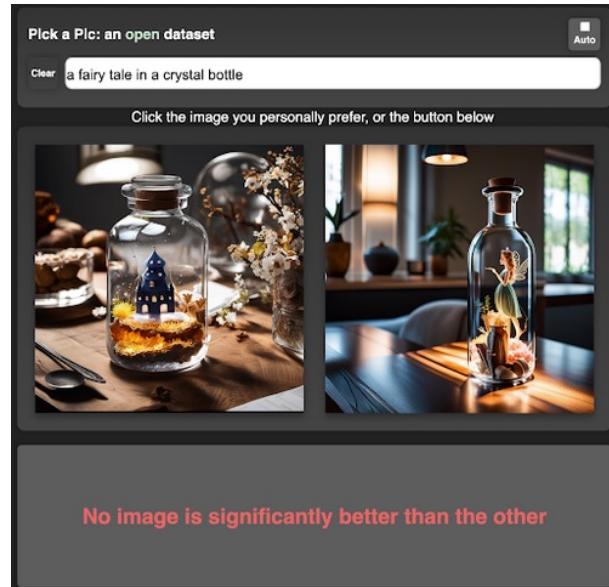
<Diffusion-DPO 모델로 생성한 이미지 (SDXL 1.0 fine-tuning)>

Diffusion-DPO

DPO for Diffusion Models

❖ Dataset

- **Pick-a-Pic** [2023.5.2] 851k crowdsourced 데이터셋 사용. Pick-a-Pic은 웹 UI에서 사람들에게 이미지 쌍에 대해 선호 평가를 매기도록 하여 수집됨
- Synthesized image pair에 대한 (미적 수준, 프롬프트 반영 정도가 고려된) **인간 선호도** 정보 포함 (이미지는 SDXL-Beta, Dreamlike (fine-tuned SD 1.5)로부터 생성)
- Pick-a-Pic 논문에서는 데이터셋 제작과 더불어 이 데이터셋을 이용해 RLHF 방식으로 **선호도를 예측하는 reward model 'PickScore'**를 학습하기도 함



<웹 UI 예시. 유저는 이미지 생성모델이 만든 두 이미지 중 더 선호하는 이미지를 선택>



<데이터 구성 예시. (1) 텍스트 프롬프트 (2) 선호되지 않는 이미지 (3) 선호 이미지로 구성>

Diffusion-DPO

DPO for Diffusion Models

❖ Dataset

- **Pick-a-Pic** [2023.5.2] 851k crowdsourced 데이터셋 사용. Pick-a-Pic은 웹 UI에서 사람들에게 이미지 쌍에 대해 선호 평가를 매기도록 하여 수집됨
- Synthesized image pair에 대한 (미적 수준, 프롬프트 반영 정도가 고려된) **인간 선호도** 정보 포함 (이미지는 SDXL-Beta, Dreamlike (fine-tuned SD 1.5)로부터 생성)
- Pick-a-Pic 논문에서는 데이터셋 제작과 더불어 이 데이터셋을 이용해 RLHF 방식으로 **선호도를 예측하는 reward model 'PickScore'**를 학습하기도 함

"A rabbit"



기존: 이미지-캡션 pair에 대해 학습

"A bird with 8 spider legs"



Diffusion-DPO: 주어진 캡션과 이미지1, 이미지2에 대해 인간이 선호하는 이미지를 생성하도록 학습

Diffusion-DPO

DPO for Diffusion Models

❖ 손실함수 정의

기존 DPO loss: $\mathcal{L}_{\text{DPO}}(\pi_\theta; \pi_{\text{ref}}) = -\mathbb{E}_{(x, y_w, y_l) \sim \mathcal{D}} \left[\log \sigma \left(\beta \log \frac{\pi_\theta(y_w | x)}{\pi_{\text{ref}}(y_w | x)} - \beta \log \frac{\pi_\theta(y_l | x)}{\pi_{\text{ref}}(y_l | x)} \right) \right]$

Diffusion-DPO loss: $L_{\text{DPO-Diffusion}}(\theta) = -\mathbb{E}_{(\mathbf{x}_0^w, \mathbf{x}_0^l) \sim \mathcal{D}} \log \sigma \left(\beta \mathbb{E}_{\substack{\mathbf{x}_{1:T}^w \sim p_\theta(\mathbf{x}_{1:T}^w | \mathbf{x}_0^w) \\ \mathbf{x}_{1:T}^l \sim p_\theta(\mathbf{x}_{1:T}^l | \mathbf{x}_0^l)}} \left[\log \frac{p_\theta(\mathbf{x}_{0:T}^w)}{p_{\text{ref}}(\mathbf{x}_{0:T}^w)} - \log \frac{p_\theta(\mathbf{x}_{0:T}^l)}{p_{\text{ref}}(\mathbf{x}_{0:T}^l)} \right] \right)$ (text condition c 생략)

Since sampling from $p_\theta(\mathbf{x}_{1:T} | \mathbf{x}_0)$ is intractable, we utilize $q(\mathbf{x}_{1:T} | \mathbf{x}_0)$

$$= -\log \sigma \left(\beta \mathbb{E}_{\substack{\mathbf{x}_{1:T}^w \sim q(\mathbf{x}_{1:T}^w | \mathbf{x}_0^w), \mathbf{x}_{1:T}^l \sim q(\mathbf{x}_{1:T}^l | \mathbf{x}_0^l)}} T \mathbb{E}_t \left[\log \frac{p_\theta(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)}{p_{\text{ref}}(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)} - \log \frac{p_\theta(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l)}{p_{\text{ref}}(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l)} \right] \right)$$

Since sampling from $p_\theta(\mathbf{x}_{1:T} | \mathbf{x}_0)$ is intractable, we utilize $q(\mathbf{x}_{1:T} | \mathbf{x}_0)$

$$\leq -\mathbb{E}_{t, \mathbf{x}_t^w \sim q(\mathbf{x}_t^w | \mathbf{x}_0^w), \mathbf{x}_t^l \sim q(\mathbf{x}_t^l | \mathbf{x}_0^l)} \log \sigma \left(\beta T \mathbb{E}_{\substack{\mathbf{x}_{t-1}^w \sim q(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w, \mathbf{x}_0^w), \mathbf{x}_{t-1}^l \sim q(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l, \mathbf{x}_0^l)}} \left[\log \frac{p_\theta(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)}{p_{\text{ref}}(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)} - \log \frac{p_\theta(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l)}{p_{\text{ref}}(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l)} \right] \right)$$

$$\begin{aligned} &= -\mathbb{E}_{t, \mathbf{x}_t^w \sim q(\mathbf{x}_t^w | \mathbf{x}_0^w), \mathbf{x}_t^l \sim q(\mathbf{x}_t^l | \mathbf{x}_0^l)} \log \sigma \left(-\beta T (\mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^w | \mathbf{x}_{0,t}^w) \| p_\theta(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)) - \mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^w | \mathbf{x}_{0,t}^w) \| p_{\text{ref}}(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)) \right. \\ &\quad \left. - (\mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^l | \mathbf{x}_{0,t}^l) \| p_\theta(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l)) + \mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^l | \mathbf{x}_{0,t}^l) \| p_{\text{ref}}(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l))) \right) \end{aligned}$$

Diffusion-DPO

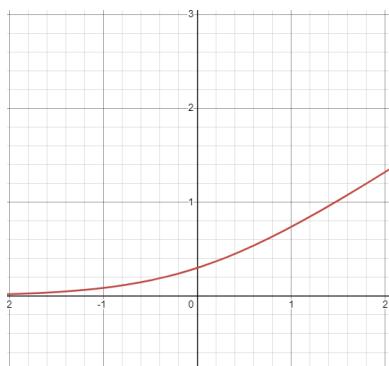
DPO for Diffusion Models

$$\text{기준 디퓨전 모델 loss: } \mathbb{E}_{\mathbf{x}_0, \epsilon} \left[\frac{\beta_t^2}{2\sigma_t^2 \alpha_t (1 - \bar{\alpha}_t)} \left\| \epsilon - \underbrace{\epsilon_\theta(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t)}_{= \epsilon_\theta(x_t, t)} \right\|^2 \right]$$

❖ 손실함수 정의

$$\begin{aligned}
L_{\text{DPO-Diffusion}}(\theta) &\leq -\mathbb{E}_{t, \mathbf{x}_t^w \sim q(\mathbf{x}_t | \mathbf{x}_0^w), \mathbf{x}_t^l \sim q(\mathbf{x}_t | \mathbf{x}_0^l)} \log \sigma \left(-\beta T (\mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^w | \mathbf{x}_{0,t}^w) \| p_\theta(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)) - \mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^w | \mathbf{x}_{0,t}^w) \| p_{\text{ref}}(\mathbf{x}_{t-1}^w | \mathbf{x}_t^w)) \right. \\
&\quad \left. - (\mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^l | \mathbf{x}_{0,t}^l) \| p_\theta(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l)) + \mathbb{D}_{\text{KL}}(q(\mathbf{x}_{t-1}^l | \mathbf{x}_{0,t}^l) \| p_{\text{ref}}(\mathbf{x}_{t-1}^l | \mathbf{x}_t^l))) \right) \\
&\quad \text{∵ 두 정규분포 사이의 KL divergence 정의} \\
&= -\mathbb{E}_{t, \epsilon^w, \epsilon^l} \log \sigma (-\beta T \omega(\lambda_t) (\|\epsilon^w - \epsilon_\theta(\mathbf{x}_t^w, t)\|^2 - \|\epsilon^w - \epsilon_{\text{ref}}(\mathbf{x}_t^w, t)\|^2 - (\|\epsilon^l - \epsilon_\theta(\mathbf{x}_t^l, t)\|^2 - \|\epsilon^l - \epsilon_{\text{ref}}(\mathbf{x}_t^l, t)\|^2))) \\
&\quad (1) \qquad \qquad \qquad (2) \qquad \qquad \qquad (3) \qquad \qquad \qquad (4)
\end{aligned}$$

- 이 loss function은 어떤 의미를 가질까?



$$y = -\log \sigma(-x)$$

; 작을수록 좋음 →

선호 이미지에 대해

- (1) fine-tuned model이 예측한 noise의 정확도가
 - (2) pre-trained model이 예측한 noise의 정확도보다 높을수록 좋음

• 클수록 좋음 →

선호하지 않는 이미지에 대해

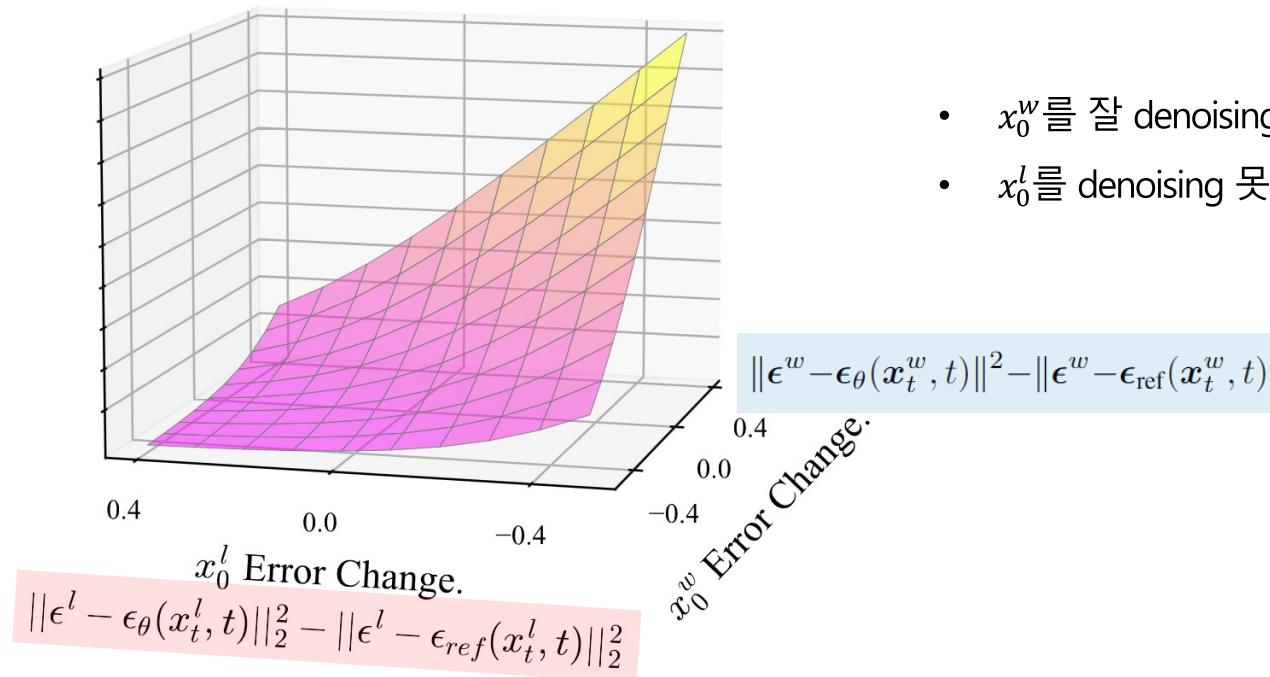
- (3) fine-tuned model이 예측한 noise의 정확도가
 - (4) pre-trained model이 예측한 noise의 정확도보다 낮을수록 좋음

Diffusion-DPO

DPO for Diffusion Models

❖ 손실함수 정의

$$L_{\text{DPO-Diffusion}}(\theta) \leq -\mathbb{E}_{t, \epsilon^w, \epsilon^l} \log \sigma(-\beta T \omega(\lambda_t) (\|\epsilon^w - \epsilon_\theta(x_t^w, t)\|^2 - \|\epsilon^w - \epsilon_{\text{ref}}(x_t^w, t)\|^2 - (\|\epsilon^l - \epsilon_\theta(x_t^l, t)\|^2 - \|\epsilon^l - \epsilon_{\text{ref}}(x_t^l, t)\|^2)))$$



- x_0^w 를 잘 denoising 할 수록 loss 감소
- x_0^l 를 denoising 못 할 수록 loss 감소

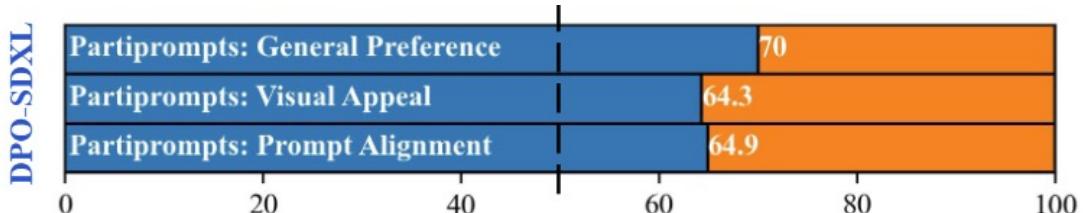
<Loss surface visualization>

Diffusion-DPO

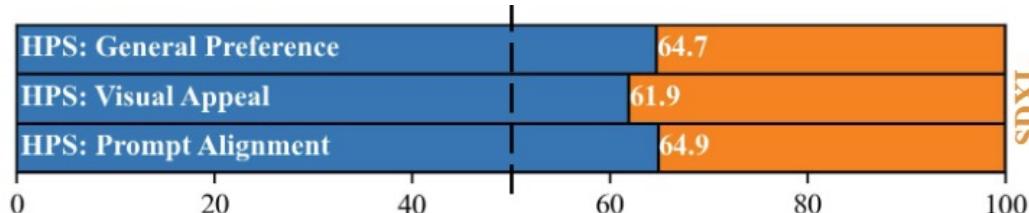
Experiments

❖ 실험 및 평가

- Pick-a-Pic 851k 데이터셋을 이용해 **Stable Diffusion(SD) 1.5**와 **Stable Diffusion XL (SDXL) 1.0** 모델 fine-tuning
- 테스트 시 벤치마크 데이터셋 Partiprompts, HPSv2의 캡션 1632개/3200개로 평가 → Diffusion-DPO-tuned 모델과 baseline 모델 비교
- 모델이 만든 이미지에 대해 human evaluator가 선호도 평가. 이때 다음 기준 고려
 1. 일반적 선호 – 주어진 프롬프트에 대해 어떤 이미지를 더 선호하는지
 2. 시각적 선호도 – 프롬프트는 고려하지 않고 어떤 이미지가 더 시각적으로 매력적인지
 3. 프롬프트 정렬 – 어떤 이미지가 텍스트 프롬프트와 더 잘 맞는지



<Partiprompts 캡션 이용>



<HPSv2 캡션 이용>

- 모든 선호도 평가지표에서 baseline 모델보다 Diffusion-DPO-tuned 모델이 더 높은 선호를 보임



<Pick-a-Pic 데이터셋>

Diffusion-DPO

Experiments

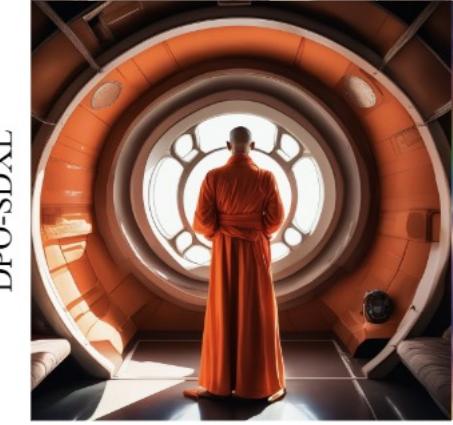
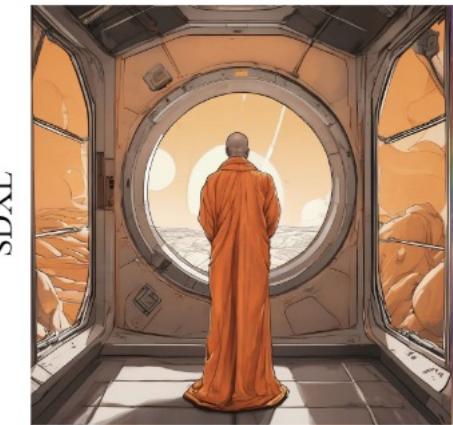
❖ 실험 및 평가

A monk in an orange robe by a round window in a spaceship in dramatic lighting

A smiling beautiful sorceress wearing a high necked blue suit surrounded by swirling rainbow aurora, hyper-realistic, cinematic, post-production

Concept art of a mythical sky alligator with wings, nature documentary

A galaxy-colored figurine is floating over the sea at sunset, photorealistic



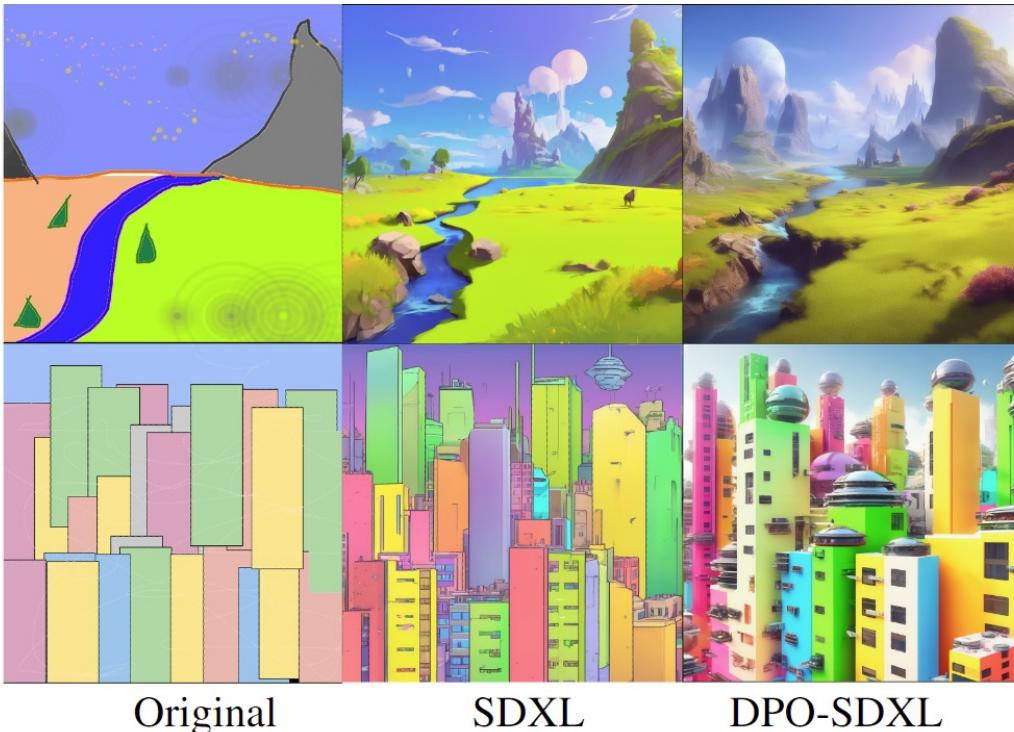
- 샘플링 프롬프트를 더 잘 반영
- Human aesthetic preference에 더 align
- High contrast, vivid colors, fine detail, ...

Diffusion-DPO

Experiments

❖ 실험 및 평가

- DPO에서는 $\beta = 0.1$ 사용, Diffusion-DPO는 $\beta = 2\sim5$ 사용
→ β 가 너무 작으면 디퓨전 모델이 pure reward scoring model로 악화, β 가 너무 크면 KL divergence 제약이 강해져 학습 안됨
- RLHF 및 DPO의 첫 번째 step이었던 supervised fine-tuning은 크게 효과가 없었음 (SD는 기존 모델에 대해 win rate 5.5%p 증가, SDXL은 오히려 감소)



- 대략적인 스케치 정보를 주는 SDEdit 방식으로 이미지 생성
- DPO-SDXL이 더 visually appealing

Direct Consistency Optimization (DCO)

DPO for Customization

❖ DPO loss를 Customization에 이용하자

- Diffusion-DPO는 디퓨전 모델이 인간의 선호도를 반영하는 이미지를 생성하도록 학습
- 이번엔 인간의 선호도가 아닌 consistency 유지를 목적으로 DPO loss를 이용하여 디퓨전 모델을 학습시켜보자
- 캡션 c 에 대해, reference data \mathcal{D} 와 모델이 생성한 이미지 x 사이의 consistency를 reward로 정의 $\rightarrow r(\mathbf{x}, \mathbf{c}; \mathcal{D}_{\text{ref}}) := r(\mathbf{x}, \mathbf{c})$



<Personalization>



<Stylization>

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 손실함수 정의

DPO에서 정의한 reward function: $r(x, y) = \beta \log \frac{\pi_r(y | x)}{\pi_{\text{ref}}(y | x)} + \beta \log Z(x)$

DCO에서 정의한 reward function: $\hat{r}(\mathbf{x}_{0:T}, \mathbf{c}) = \beta \log \frac{p_\theta(\mathbf{x}_{0:T} | \mathbf{c})}{p_\phi(\mathbf{x}_{0:T} | \mathbf{c})} + \beta \log Z(\mathbf{c}) \rightarrow$ 모든 marginal trajectories를 포함



marginal의 expectation

$$r(\mathbf{x}_0, \mathbf{c}) = \mathbb{E}_{\mathbf{x}_{1:T} \sim p_\theta(\mathbf{x}_{1:T} | \mathbf{x}_0, \mathbf{c})} \left[\beta \log \frac{p_\theta(\mathbf{x}_{0:T} | \mathbf{c})}{p_\phi(\mathbf{x}_{0:T} | \mathbf{c})} \right] + \beta \log Z(\mathbf{c})$$

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 손실함수 정의

$$r(\mathbf{x}_0, \mathbf{c}) = \mathbb{E}_{\mathbf{x}_{1:T} \sim p_\theta(\mathbf{x}_{1:T} | \mathbf{x}_0, \mathbf{c})} \left[\beta \log \frac{p_\theta(\mathbf{x}_{0:T} | \mathbf{c})}{p_\phi(\mathbf{x}_{0:T} | \mathbf{c})} \right] + \beta \log Z(\mathbf{c})$$



$$\begin{aligned} r(\mathbf{x}_0, \mathbf{c}) / \beta &\approx \mathbb{E}_{q(\mathbf{x}_{1:T} | \mathbf{x}_0)} \left[\log \frac{p_\theta(\mathbf{x}_{0:T} | \mathbf{c})}{p_\phi(\mathbf{x}_{0:T} | \mathbf{c})} \right] \\ &= \mathbb{E}_{q(\mathbf{x}_{1:T} | \mathbf{x}_0)} \left[\sum_{t=1}^T \log \frac{p_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{c})}{p_\phi(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{c})} \right] \\ &= \mathbb{E}_{q(\mathbf{x}_{1:T} | \mathbf{x}_0)} \left[\sum_{t=1}^T \log \frac{p_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{c})}{q(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{x}_0)} - \sum_{t=1}^T \log \frac{p_\phi(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{c})}{q(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{x}_0)} \right] \\ &= \sum_{t=1}^T \mathbb{E}_{q(\mathbf{x}_t | \mathbf{x}_0)} \left[-D_{\text{KL}}(q(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{x}_0) \| p_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{c})) + D_{\text{KL}}(q(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{x}_0) \| p_\phi(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{c})) \right] \\ &= \mathbb{E}_{\boldsymbol{\varepsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}), t \sim \mathcal{U}[1, T]} \left[-T\omega(t)(\|\boldsymbol{\varepsilon}_\theta(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2 - \|\boldsymbol{\varepsilon}_\phi(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2) \right], \end{aligned}$$

- Diffusion-DPO와 유사하게
intractable p_θ 대신 q 이용 + Jensen's inequality 이용

$$\mathcal{L}_{\text{DCO}}(\theta) := \mathbb{E}_{(\mathbf{x}, \mathbf{c}) \sim \mathcal{D}_{\text{ref}}, t \sim \mathcal{U}(0, T), \boldsymbol{\varepsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})} \left[-\log \sigma(-\beta T\omega(t)(\|\boldsymbol{\varepsilon}_\theta(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2 - \|\boldsymbol{\varepsilon}_\phi(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2)) \right]$$

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 손실함수 정의

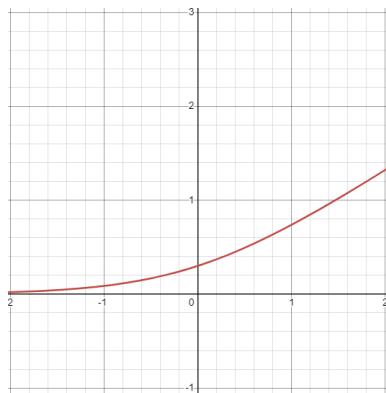
$$\mathcal{L}_{\text{DCO}}(\theta) := \mathbb{E}_{(\mathbf{x}, \mathbf{c}) \sim \mathcal{D}_{\text{ref}}, t \sim \mathcal{U}(0, T), \boldsymbol{\varepsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})} \left[-\log \sigma(-\beta T \omega(t) (\|\boldsymbol{\varepsilon}_\theta(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2 - \|\boldsymbol{\varepsilon}_\phi(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2)) \right]$$

모든 reference data x , 캡션 c ,
timestep t , Gaussian noise ε 에 대해

(1)

(2)

- 이 loss function은 어떤 의미를 가질까?



$$y = -\log \sigma(-x)$$



: 작을수록 좋음 →

선호 이미지에 대해

- (1) fine-tuned model이 예측한 noise의 정확도가
(2) pre-trained model이 예측한 noise의 정확도보다 높을수록 좋음

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 손실함수 정의

$$\mathcal{L}_{\text{DCO}}(\theta) := \mathbb{E}_{(\mathbf{x}, \mathbf{c}) \sim \mathcal{D}_{\text{ref}}, t \sim \mathcal{U}(0, T), \boldsymbol{\varepsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})} \left[-\log \sigma(-\beta T \omega(t) (\|\boldsymbol{\varepsilon}_\theta(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2 - \|\boldsymbol{\varepsilon}_\phi(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2)) \right]$$

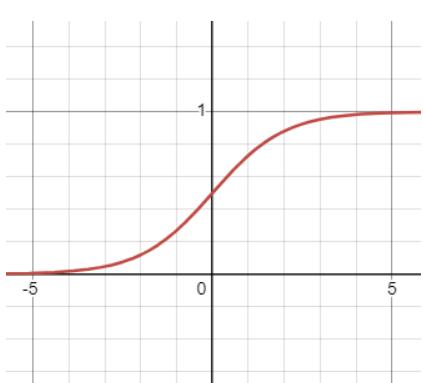
모든 reference data x , 캡션 c ,
timestep t , Gaussian noise ε 에 대해

- Gradient analysis of DCO loss

기준 디퓨전 loss와 동일

$$\nabla_\theta \mathcal{L}_{\text{DCO}}(\theta) \propto (1 - \sigma(d_t)) \nabla_\theta \|\boldsymbol{\varepsilon}_\theta(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2$$

$$\text{where } d_t = -\beta T (\|\boldsymbol{\varepsilon}_\theta(\mathbf{x}_t, \mathbf{c}; t) - \boldsymbol{\varepsilon}\|_2^2 - \|\boldsymbol{\varepsilon}_\phi(\mathbf{x}_t; \mathbf{c}, t) - \boldsymbol{\varepsilon}\|_2^2)$$



fine-tuned model이 예측한 노이즈의 오차가 클수록,
Pre-trained model이 예측한 노이즈의 오차가 작을수록
(=모델이 노이즈를 잘못 예측할수록) 큰 기증치 부여



fine-tuned model이 노이즈를 잘 예측하도록 학습

Direct Consistency Optimization (DCO)

DPO for Customization

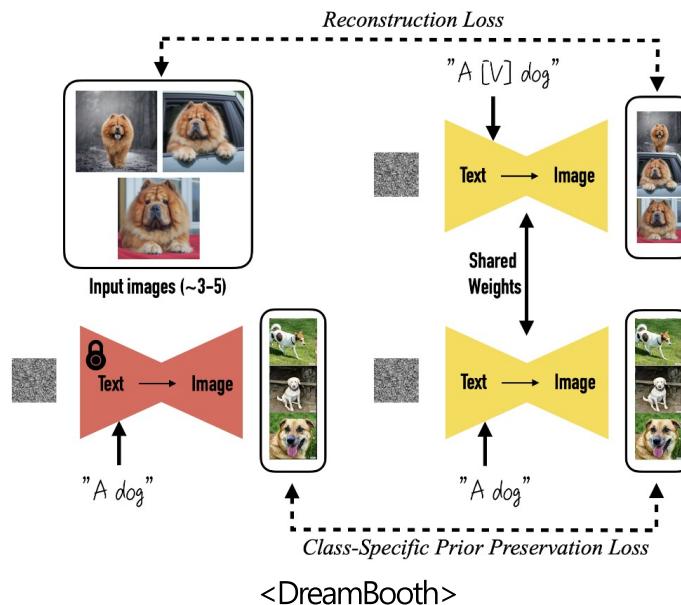
❖ 손실함수 정의

기존 디퓨전 loss와 동일

$$\nabla_{\theta} \mathcal{L}_{DCO}(\theta) \propto (1 - \sigma(d_t)) \nabla_{\theta} \|\varepsilon_{\theta}(\mathbf{x}_t; \mathbf{c}, t) - \varepsilon\|_2^2$$

where $d_t = -\beta T(\|\varepsilon_{\theta}(\mathbf{x}_t, \mathbf{c}; t) - \varepsilon\|_2^2 - \|\varepsilon_{\phi}(\mathbf{x}_t; \mathbf{c}, t) - \varepsilon\|_2^2)$

- DCO loss의 장점



- 기존 personalization 방법론인 DreamBooth는 prior preservation을 위해 추가 데이터셋을 구축하고 학습해야 했음
- 그러나 DCO는 기존 pre-trained 모델과 너무 멀어지지 않도록 하는 DPO의 KL divergence 개념을 포함하고 있으므로 prior preservation이 불필요

Direct Consistency Optimization (DCO)

DPO for Customization

❖ Reward Guidance

$$\hat{\varepsilon}(\mathbf{x}_t; \mathbf{c}, t) = \omega_{rg} (\varepsilon_\theta(\mathbf{x}_t; \mathbf{c}, t) - \varepsilon_\phi(\mathbf{x}_t; \mathbf{c}, t)) + \omega_{text} (\varepsilon_\phi(\mathbf{x}_t; \mathbf{c}, t) - \varepsilon_\phi(\mathbf{x}_t, t)) + \varepsilon_\phi(\mathbf{x}_t, t)$$

ε_θ : fine-tuned 모델

ε_ϕ : pre-trained 모델

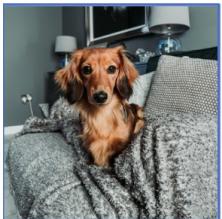
- 기존에는 fine-tuned 모델로만 노이즈를 계산. Reward guidance를 통해 pre-trained 모델과 fine-tuned 모델의 output을 분리하여 조절할 수 있도록 함
- ω_{text} 는 일반적인 CFG (classifier free guidance) 값, ω_{rg} 는 fine-tuned 모델의 output 힘을 조절하는 scaler (논문에선 2.0, 3.0, 4.0, 5.0 사용)

❖ Comprehensive caption

Compact caption

"A photo of [V] dog"

Reference



[V] dog with lake
in the background



[V] dog in cartoon
line drawing style

Comprehensive caption

"A photo of a **dog** sitting on a couch covered with grey blanket in a living room, indoor lighting style"



dog with lake in
the background



dog in cartoon
line drawing style

- 단순한 캡션으로 학습하는 것보다 이미지를 최대한 잘 설명하는 캡션으로 학습하면 과적합을 방지하고 목표 대상을 다른 대상들과 분리하여 더 잘 표현할 수 있음

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 실험 및 평가

- Stable Diffusion XL (SDXL) 1.0 + LoRA fine-tuning



<personalization 비교>

DB: DreamBooth

DB+p.p.: DreamBooth + prior preservation

- 기존 방법론보다 대상의 identity를 잘 유지함+샘플링 프롬프트에 더 충실

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 실험 및 평가

- Stable Diffusion XL (SDXL) 1.0 + LoRA fine-tuning



*A {Christmas tree, butterfly, piano}
in melting golden 3D rendering style*



*A {butterfly, coffee maker, piano}
in watercolor painting style*

<Stylization 비교>

- 기존 방법론보다 대상의 style만을 잘 포착하여 과적합 방지

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 실험 및 평가

- **Merge:** personalization (content) + Stylization (style)



- 기존 방법론보다 대상의 identity 및 style을 더 잘 유지하면서 병합
- Pre-trained 모델과 너무 멀어지지 않고 잘 어울릴 수 있도록 하는 DCO loss 자체 제작 덕분에 LoRA fine-tuned 개별 모델들도 서로와 잘 어울리는 것

DB Merge



DB Merge: DreamBooth loss로 학습한
content LoRA와 style LoRA weight을 단순히 병합

DB ZipLoRA



DB ZipLoRA: DreamBooth loss로 학습한
content LoRA와 style LoRA weight을 ZipLoRA 방식으로 병합

DCO Merge
(ours)



DCO Merge: DCO loss로 학습한
content LoRA와 style LoRA weight을 단순히 병합

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 실험 및 평가

- **Merge:** personalization (content) + Stylization (style) – 다양한 샘플링 프롬프트와 결합



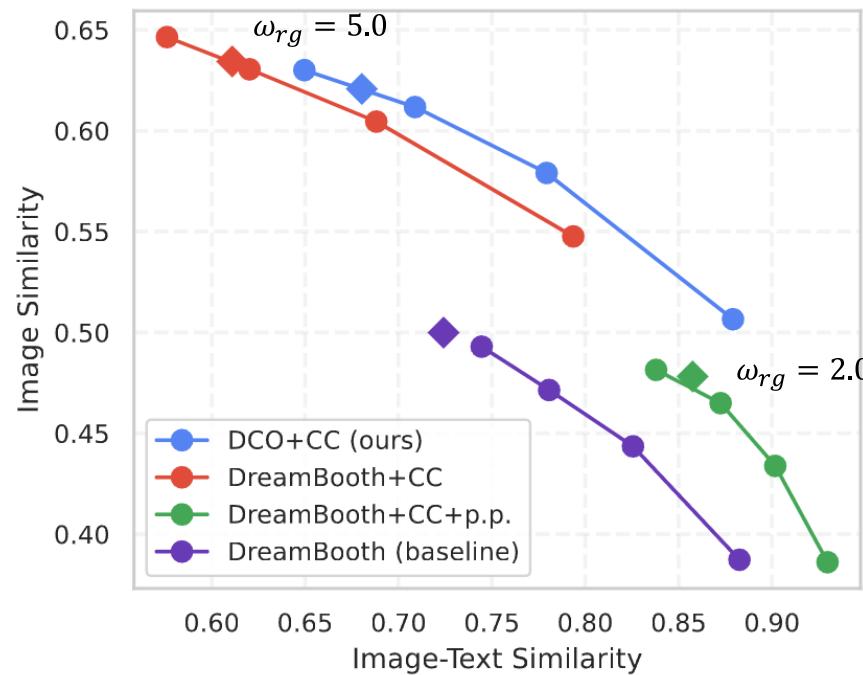
- Content와 style을 동시에 잘 반영하면서 추가적인 프롬프트에 충실한 이미지 생성

Direct Consistency Optimization (DCO)

DPO for Customization

❖ 실험 및 평가

- 정량적 평가



CC: Comprehensive caption

p.p.: prior preservation

※ **SigLIP**: CLIP과 동일하게 텍스트와 이미지를 같은 공간 상에서 학습한 모델
CLIP과 다른 점은 loss를 softmax에서 sigmoid로 바꾼 것

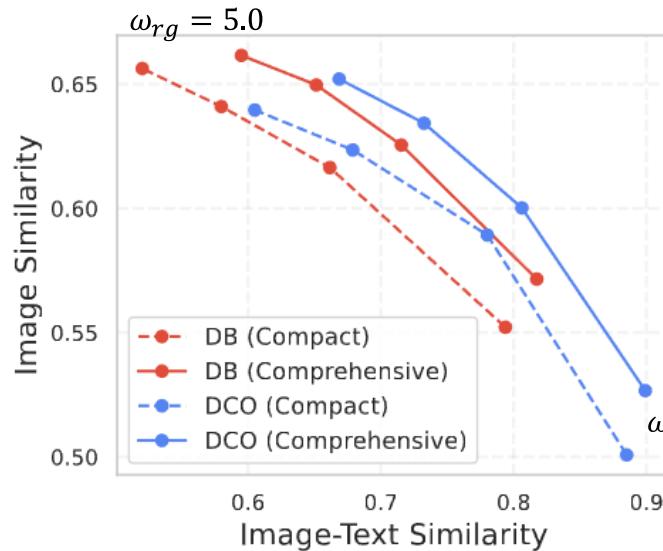
- **Image similarity**: DINOv2 score 이용
Reference 이미지와 synthesized 이미지를 DINOv2에 넣고 임베딩 추출
두 임베딩의 코사인 유사도를 image similarity로 정의
→ 값이 클수록 레퍼런스 이미지의 특징을 잘 잡도록 학습된 것
- **Image-text similarity**: SigLIP score 이용
샘플링 프롬프트를 SigLIP 텍스트 인코더에 넣어 임베딩 추출
+ synthesized 이미지를 SigLIP 이미지 인코더에 넣어 임베딩 추출
두 임베딩의 코사인 유사도를 image-text similarity로 정의
→ 값이 클수록 텍스트와 이미지 사이 align이 잘 맞는 것
- **원형 point 4개**: 각각 $\omega_{rg} = 5.0, 4.0, 3.0, 2.0$ 으로 샘플링
- **사각형 point**: 일반적인 CFG scale만으로 샘플링
- 기존 방법론에 비해 DCO가 **Image similarity**와 **Image-text similarity**에서 모두 높은 성능 기록

Direct Consistency Optimization (DCO)

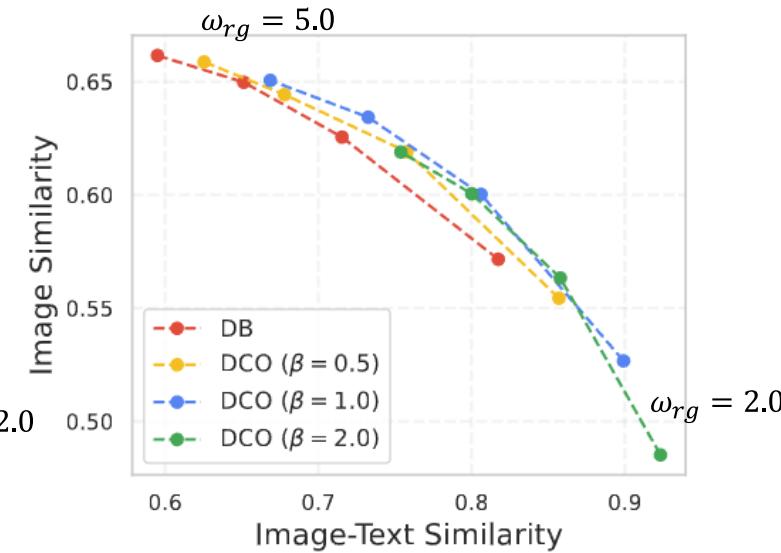
DPO for Customization

❖ 실험 및 평가

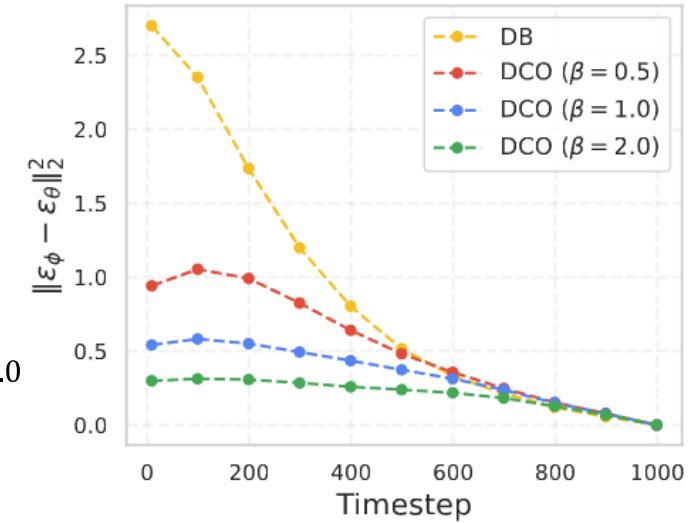
- Ablation study



(a) Ablation on comprehensive caption



(b) Ablation on β



(c) Noise distance

DCO가 pre-trained model output과 fine-tuned model output 사이 오차가 더 작음
+ 큰 값의 β 로 학습시킬수록 (=KL regularization을 강하게 걸수록) 오차가 더 작음

고맙습니다