

2024년 3월 22일 DMQA 연구실 오픈 세미나

The Two Formulations of Diffusion Models



이종현

Introduction

발표자 소개



❖ 이종현 (Jong Hyun Lee)

- 고려대학교 산업경영공학과 석사 과정 (2022.09 ~ Present)
- Data Mining & Quality Analytics Lab

❖ Research Interests

- Computer Vision
- Deep Generative Models
- Diffusion Models

❖ Contact

- E-mail: tomtom1103@korea.ac.kr

Introduction

Generative Models

❖ 생성모델 (Generative Models)

- Text 를 입력하면 그림을 그려주는 AI 로 큰 화재
- 엄청난 속도로 발전하는 Domain



“A drawing of a cat”.



“Horse eating a cupcake”.



“A 3D rendering of a temple”.

CLIPDraw, 2021

Introduction

Generative Models

❖ 생성모델 (Generative Models)

- Text 를 입력하면 그림을 그려주는 AI 로 큰 화재
- 엄청난 속도로 발전하는 Domain



“A drawing of a cat”.



“Horse eating a cupcake”.



“A 3D rendering of a temple”.

CLIPDraw, 2021




Sora, 2024

Introduction

Generative Models

❖ Diffusion Models

- Generative Models 중 가장 큰 성공을 이룬 model : Diffusion Models
- 비교적 느리지만, 높은 Quality 와 다양한 종류의 샘플을 생성 할 수 있다는 장점
- 그 근간에는 Forward / Reverse Process 가 있음




Introduction

Generative Models

❖ Diffusion Models

- Generative Models 중 가장 큰 성공을 이룬 model : Diffusion Models
- 비교적 느리지만, 높은 Quality 와 다양한 종류의 샘플을 생성 할 수 있다는 장점
- 그 근간에는 Forward / Reverse Process 가 있음
- Forward Process : 이미지 (x_0) 가 완전한 Gaussian Noise (x_T) 가 될 때까지 Gaussian Noise 를 점진적으로 추가하는 Markov Process
- Reverse Process : Gaussian Noise (x_T) 에서 점진적으로 Gaussian Noise 를 제거하여 이미지 (x_0) 를 복원하는 Markov Process




Introduction

Generative Models

❖ Diffusion Models

- Generative Models 중 가장 큰 성공을 이룬 model : Diffusion Models
- 비교적 느리지만, 높은 Quality 와 다양한 종류의 샘플을 생성 할 수 있다는 장점
- 그 근간에는 Forward / Reverse Process 가 있음
- Forward Process : 이미지 (x_0) 가 완전한 Gaussian Noise (x_T) 가 될 때까지 Gaussian Noise 를 점진적으로 추가하는 Markov Process
- Reverse Process : Gaussian Noise (x_T) 에서 점진적으로 Gaussian Noise 를 제거하여 이미지 (x_0) 를 복원하는 Markov Process
- 이런 Diffusion Model 을 Formulating 하는 방법은 크게 두가지가 있으며, 하나의 Unified Framework 또한 존재



Introduction

Generative Models

❖ Diffusion Models

- Generative Models 중 가장 큰 성공을 이룬 model : Diffusion Models
- 비교적 느리지만, 높은 Quality 와 다양한 종류의 샘플을 생성 할 수 있다는 장점
- 그 근간에는 Forward / Reverse Process 가 있음
- Forward Process : 이미지 (x_0) 가 완전한 Gaussian Noise (x_T) 가 될 때까지 Gaussian Noise 를 점진적으로 추가하는 Markov Process
- Reverse Process : Gaussian Noise (x_T) 에서 점진적으로 Gaussian Noise 를 제거하여 이미지 (x_0) 를 복원하는 Markov Process
- 이런 Diffusion Model 을 Formulating 하는 방법은 크게 두가지가 있으며, 하나의 Unified Framework 또한 존재

종료 Fusion Probabilistic Models (DDPM)

• Reverse process: 완전 노이즈 (x_T) + 노이즈 제거 → 이미지(x_0)

• 노이즈를 제거하는 reverse process를 학습할 수 있다면 완전 노이즈로부터 어떠한 생성 가능



Score-based Generative Models and Diffusion Models

발표자: 조한샘

2022년 2월 11일
오후 1시 ~
온라인 비디오 시청 (YouTube)

세미나 정보 보기 →

종료 Conditional Diffusion Models




Jong Hyun Lee
2023.06.09

Conditional Diffusion Models

발표자: 이종현


2023년 6월 16일
오전 12시 ~
온라인 비디오 시청 (YouTube)

세미나 정보 보기 →



Introduction

Generative Models



Two Formulations


VP

❖ The Variance Preserving Formulation (VP)

- 대부분의 사람들이 익숙한 Diffusion Models (DDPM, Stable Diffusion, DALL-E, etc..) 는 이 Variance Preserving Formulation 을 따름
- Variance Preserving: 분산을 보존하는 Formulation
- Forward Process 에서 이미지가 점진적으로 Gaussian Noise 가 될 때 확인 가능

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\alpha_t \mathbf{x}_0, \sigma_t^2 \mathbf{I})$$

$$\mathbf{x}_t = \alpha_t \mathbf{x}_0 + \sigma_t \epsilon$$



Two Formulations



VP

❖ The Variance Preserving Formulation (VP)

- 대부분의 사람들이 익숙한 Diffusion Models (DDPM, Stable Diffusion, DALL-E, etc..) 는 0 | Variance Preserving Formulation 을 따름
- Variance Preserving: 분산을 보존하는 Formulation
- Forward Process 에서 이미지가 점진적으로 Gaussian Noise 가 될 때 확인 가능

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\alpha_t \mathbf{x}_0, \sigma_t^2 \mathbf{I})$$

$$\mathbf{x}_t = \alpha_t \mathbf{x}_0 + \sigma_t \epsilon$$



Two Formulations

VE


❖ The Variance Exploding Formulation (VE)

- 반면 Variance Exploding Formulation 도 존재 (NCSN, EDM, etc..)
- Variance Exploding : VP sigma 의 max 값은 1이지만, **VE 는 그 이상으로 설정**
- VP alpha 값은 timestep 이 증가할수록 작아지지만, **VE에선 constant 값 1로 설정**

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\alpha_t \mathbf{x}_0, \sigma_t^2 \mathbf{I})$$

$$\mathbf{x}_t = \alpha_t \mathbf{x}_0 + \sigma_t \epsilon$$

$$\alpha_t = 1, \sigma_{\max} = 80$$



Two Formulations

VE



❖ The Variance Exploding Formulation (VE)

- 반면 Variance Exploding Formulation 도 존재 (NCSN, EDM, etc..)
- Variance Exploding : VP sigma 의 max 값은 1이지만, **VE 는 그 이상으로 설정**
- VP alpha 값은 timestep 이 증가할수록 작아지지만, **VE에선 constant 값 1로 설정**

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\alpha_t \mathbf{x}_0, \sigma_t^2 \mathbf{I})$$

$$\mathbf{x}_t = \alpha_t \mathbf{x}_0 + \sigma_t \epsilon$$

$$\alpha_t = 1, \sigma_{\max} = 80$$



Two Formulations

VP vs. VE



❖ VP vs. VE Formulations

- VP Formulation 은 Text to image Diffusion models 에서 많이 사용
- VE Formulation 은 Theoretical 연구에서 많이 사용

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\alpha_t \mathbf{x}_0, \sigma_t^2 \mathbf{I})$$

$$\mathbf{x}_t = \alpha_t \mathbf{x}_0 + \sigma_t \epsilon$$

	Variance Preserving (VP)	Variance Exploding (VE)
Models	DDPM, Stable Diffusion, DALL-E, VDM, etc	NCSN, Score SDE, EDM, CM
Sigma	$\lim_{t \rightarrow 1} \sigma_t = 1$	$\lim_{t \rightarrow 1} \sigma_t = \sigma_{\max}$
Alpha	$\lim_{t \rightarrow 1} \alpha_t = 0$	const. $\alpha_t = 1$



Two Formulations

VP vs. VE



❖ VP vs. VE Formulations

- VP Formulation 은 Text to image Diffusion models 에서 많이 사용
- VE Formulation 은 Theoretical 연구에서 많이 사용
- 왜 두가지 Formulation 이 존재할까?

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\alpha_t \mathbf{x}_0, \sigma_t^2 \mathbf{I})$$

$$\mathbf{x}_t = \alpha_t \mathbf{x}_0 + \sigma_t \epsilon$$

	Variance Preserving (VP)	Variance Exploding (VE)
Models	DDPM, Stable Diffusion, DALL-E, VDM, etc	NCSN, Score SDE, EDM, CM
Sigma	$\lim_{t \rightarrow 1} \sigma_t = 1$	$\lim_{t \rightarrow 1} \sigma_t = \sigma_{\max}$
Alpha	$\lim_{t \rightarrow 1} \alpha_t = 0$	$\text{const.} \alpha_t = 1$




Two Formulations

VP vs. VE

❖ Two branches of Diffusion Models

- Diffusion Model 은 사실상 다른 이름으로 동시다발적으로 연구된 분야
- **VP Formulation : Diffusion Models**




Two Formulations

VP vs. VE

❖ Two branches of Diffusion Models

- Diffusion Model 은 사실상 다른 이름으로 동시다발적으로 연구된 분야
- VP Formulation : Diffusion Models
- VE Formulation : Score – Based Models




Two Formulations

Score – Based Models

❖ Score – Based Models

- Score란? Gradient of the log density of a distribution. 즉, 분포에 로그를 취한 값의 미분값.
- 1935년에 Ronald Fisher (Fisher Divergence) 가 처음 발견
- 특정 Random variable X 가 있고, 이 RV를 Score 만큼 미세하게 움직이면 새로운 RV는 이전 RV보다 Likelihood가 더 높음

$$\text{likelihood}(\mathbf{x}) < \text{likelihood}(\mathbf{x} + \delta \nabla_{\mathbf{x}} \log p(\mathbf{x}))$$



Two Formulations


Score – Based Models

❖ Score – Based Models

- Score 란? Gradient of the log density of a distribution. 즉, 분포에 로그를 취한 값의 미분값.
- 1935년에 Ronald Fisher (Fisher Divergence) 가 처음 발견
- 특정 Random variable X 가 있고, 이 RV 를 Score 만큼 미세하게 움직이면 새로운 RV 는 이전 RV 보다 Likelihood 가 더 높음
- 즉, 특정 RV 에 대해 Likelihood 가 높은 방향으로 pointing 을 해주는 vector field
- 아무런 Random variable 값에서 시작해도 Score 를 따라 움직이면 높은 Likelihood 의 샘플을 얻을 수 있다

$$\nabla_x \log p(x)$$

$$\text{likelihood}(x) < \text{likelihood}(x + \delta \nabla_x \log p(x))$$



Two Formulations

Score – Based Models

❖ Score – Based Models and Diffusion Models

- 아무런 Random variable 값에서 시작해도 Score 를 따라 움직이면 높은 Likelihood 의 샘플을 얻을 수 있다
- 이런 특징을 이용해서, Random Variable 에 대해 Score 을 예측 할 수 있는 모델들이 등장 – Score – Based Models
- 하지만 그냥 Score 을 아무런 Random Variable 에 대해 예측하기보단, 이미지에 Gaussian noise 를 주입해 Score 을 예측

$$J_D(\theta) = \mathbb{E}_{x \sim q_{\text{data}}(x), \epsilon \sim \mathcal{N}(0, I)} \left[\frac{1}{2} \left\| \underbrace{s_\theta(x + \sigma\epsilon)}_{\tilde{x}} - \left(-\frac{\epsilon}{\sigma}\right) \right\|^2 \right]$$

Obj. Func. of Denoising Score Matching

Two Formulations

Score – Based Models

❖ Score – Based Models and Diffusion Models

- 아무런 Random variable 값에서 시작해도 Score 를 따라 움직이면 높은 Likelihood 의 샘플을 얻을 수 있다
- 이런 특징을 이용해서, Random Variable 에 대해 Score 을 예측 할 수 있는 모델들이 등장 – Score – Based Models
- 하지만 그냥 Score 을 아무런 Random Variable 에 대해 예측하기보단, 이미지에 Gaussian noise 를 주입해 Score 을 예측
- Modern Day Diffusion model 의 시초인 DDPM에선 Diffusion/Score based 에 대한 연관성을 인지하지만, 완벽하게 formulate 하진 않음

$$J_D(\theta) = \mathbb{E}_{x \sim q_{\text{data}}(x), \epsilon \sim \mathcal{N}(0, I)} \left[\frac{1}{2} \left\| s_{\theta}(\underbrace{x + \sigma\epsilon}_{\tilde{x}}) - \left(-\frac{\epsilon}{\sigma}\right) \right\|^2 \right]$$

Obj. Func. of Denoising Score Matching

$$L_{\text{simple}}(\theta) := \mathbb{E}_{t, \mathbf{x}_0, \epsilon} \left[\left\| \epsilon - \epsilon_{\theta}(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t) \right\|^2 \right]$$

Obj. Func. of DDPM

Two Formulations

Variational Diffusion Models

❖ Variational Diffusion Models

- VDM 이란 논문에선 Score based 와 Diffusion Model 의 output 들이 서로 상호교환 가능하단 것을 정리
- 즉, Score based models 의 목적함수로 모델을 학습시켰든, DDPM 의 목적함수로 모델을 학습시켰든 상관 없이 Diffusion Model 로도 Score 을 예측 할 수 있음

$$\hat{\mathbf{x}}_{\theta}(\mathbf{x}_t, t) = \frac{\mathbf{x}_t - \sigma_t \epsilon_{\theta}(\mathbf{x}_t, t)}{\alpha_t}$$

$$L_{\text{simple}}(\theta) := \mathbb{E}_{t, \mathbf{x}_0, \epsilon} \left[\left\| \epsilon - \epsilon_{\theta}(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t) \right\|^2 \right]$$

$$s_{\theta}(\mathbf{x}_t) = \frac{\alpha_t \hat{\mathbf{x}}_{\theta}(\mathbf{x}_t, t) - \mathbf{x}_t}{\sigma_t^2}$$

$$s_{\theta}(\mathbf{x}_t) = \frac{-\epsilon_{\theta}(\mathbf{x}_t, t)}{\sigma_t}$$


$$J_D(\theta) = \mathbb{E}_{x \sim q_{\text{data}}(x), \epsilon \sim \mathcal{N}(0, I)} \left[\frac{1}{2} \left\| \underbrace{s_{\theta}(x + \sigma \epsilon)}_{\tilde{x}} - \left(-\frac{\epsilon}{\sigma}\right) \right\|^2 \right]$$

Two Formulations

VP vs. VE

❖ Two branches of Diffusion Models

- Diffusion Model 은 사실상 다른 이름으로 동시다발적으로 연구된 분야
- VP Formulation : Diffusion Models
- VE Formulation : Score – Based Models
- **A unified Framework : Score SDE**



VP Formulation

**DDPM,
VDM**

VE Formulation

DSM,NCSN

SDE/PF-ODEs

Score SDE

CM

Consistency Models

SDE/PF-ODE

Score SDEs

❖ Score SDEs

- 먼저, ODE/SDE 란?
- ODE (Ordinary Differential Equation): 미지의 함수와 도함수의 관계를 나타낸 방정식. 보통 시간에 따라 변하는 변수의 변화량을 수식화

$$\text{ODE} : d\mathbf{x} = \mathbf{f}(\mathbf{x}, t)dt$$

SDE/PF-ODE

Score SDEs

❖ Score SDEs

- 먼저, ODE/SDE 란?
- ODE (Ordinary Differential Equation): 미지의 함수와 도함수의 관계를 나타낸 방정식. 보통 시간에 따라 변하는 RV의 변화량을 수식화
- SDE (Stochastic Differential Equation): ODE에 랜덤성이 포함된 미분방정식

$$\text{ODE} : d\mathbf{x} = \mathbf{f}(\mathbf{x}, t)dt$$

$$\text{SDE} : d\mathbf{x} = \mathbf{f}(\mathbf{x}, t)dt + g(t)d\mathbf{w}$$

SDE/PF-ODE


Score SDEs

❖ Score SDEs

- 먼저, ODE/SDE 란?
- ODE (Ordinary Differential Equation): 미지의 함수와 도함수의 관계를 나타낸 방정식. 보통 시간에 따라 변하는 RV의 변화량을 수식화
- SDE (Stochastic Differential Equation): ODE에 랜덤성이 포함된 미분방정식
- Score SDE 논문에선 Diffusion Model과 Score Based Model을 하나의 SDE로 표현할 수 있다는 것을 발견

$$\text{ODE} : d\mathbf{x} = \mathbf{f}(\mathbf{x}, t)dt$$

$$\text{SDE} : d\mathbf{x} = \mathbf{f}(\mathbf{x}, t)dt + g(t)d\mathbf{w}$$




SDE/PF-ODE

Score SDEs

❖ Score SDEs

- Diffusion SDE 는 연속적인 시간의 변화에 따른 이미지의 변화를 모델링
- Forward SDE: 아주 작은 시간의 변화 dt 와 아주 작은 노이즈의 변화 $d\mathbf{w}$ 에 대한 이미지의 변화 $d\mathbf{x}$
- Reverse SDE: Reverse SDE: 아주 작은 시간의 변화 dt 와 아주 작은 노이즈의 변화 $d\mathbf{w}$ 에 대한 이미지의 변화 $d\mathbf{x}$
- 이때 Reverse SDE 를 계산하려면 Score 값이 필요: **Diffusion Model** 과 **Score Based Model** 둘 다 활용 가능



SDE/PF-ODE

Score SDEs

❖ Score SDEs

- 이때 Reverse SDE 를 계산하려면 Score 값이 필요 : **Diffusion Model** 과 **Score Based Model** 둘 다 활용 가능
- Score SDE 논문에선 이 Framework 를 구축하면서 기존 Diffusion model 은 VP SDE (Variance Preserving), Score Based model 은 VE SDE (Variance Exploding) 이라 명명
- 이유는 각 모델의 목적함수를 보면 알 수 있음:
Diffusion model에선 이미지에 노이즈를 추가하면서 (Sigma) 동시에 이미지의 픽셀값을 Scaling 함 (Alpha)
반면 Score Based model에선 이미지를 따로 Scaling 하지 않고 노이즈만 추가함

$$J_D(\theta) = \mathbb{E}_{x \sim q_{\text{data}}(x), \epsilon \sim \mathcal{N}(0, I)} \left[\frac{1}{2} \left\| s_{\theta}(\underbrace{x + \sigma \epsilon}_{\tilde{x}}) - \left(-\frac{\epsilon}{\sigma}\right) \right\|^2 \right]$$

Obj. Func. of Denoising Score Matching

$$L_{\text{simple}}(\theta) := \mathbb{E}_{t, \mathbf{x}_0, \epsilon} \left[\left\| \epsilon - \epsilon_{\theta}(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t) \right\|^2 \right]$$

Obj. Func. of DDPM

SDE/PF-ODE

Score SDEs

❖ Score SDEs

- 이때 Reverse SDE를 계산하려면 Score 값이 필요: Diffusion Model과 Score Based Model 둘 다 활용 가능
- Score SDE 논문에선 이 Framework를 구축하면서 기존 Diffusion model은 VP (Variance Preserving), Score Based model은 VE (Variance Exploding)이라 명명
- 이유는 각 모델의 목적함수를 보면 알 수 있음:
Diffusion model에선 이미지에 노이즈를 추가하면서 (Sigma) 동시에 이미지의 픽셀값을 Scaling 함 (Alpha)
반면 Score Based model에선 이미지를 디퓨전을 SDE로 재해석하면 장점이 있나?

기존 방법대로 잘만 작동했는데?

$$J_D(\theta) = \mathbb{E}_{x \sim q_{\text{data}}(x), \epsilon \sim \mathcal{N}(0, I)} \left[\frac{1}{2} \left\| s_\theta \left(\underbrace{x + \sigma \epsilon}_{\tilde{x}} \right) - \left(-\frac{\epsilon}{\sigma} \right) \right\|^2 \right]$$

Obj. Func. of Denoising Score Matching

$$L_{\text{simple}}(\theta) := \mathbb{E}_{t, x_0, \epsilon} \left[\left\| \epsilon - \epsilon_\theta \left(\sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t \right) \right\|^2 \right]$$


Obj. Func. of DDPM

SDE/PF-ODE

Score SDEs

❖ Score SDEs

- ODE (Ordinary Differential Equations) 를 푼다: 시작점이 주어지면 끝점과 그 사이의 변화량을 알아내는 것 (Trajectory)
- Euler Method 처럼 ODE 를 위한 Solving 알고리즘을 통해 풀 수 있음



$$dx = f(x, t)dt$$

1. 시작 지점을 설정 (A_0)
2. 미분방정식 dx 계산
3. 이 dx 값은 해당 시점의 기울기 (slope)
4. 1 Step 증가: $A_1 = A_0 + \delta dx$
5. 반복

SDE/PF-ODE

Score SDEs

❖ Score SDEs

- 놀라운 점은 Diffusion Reverse SDE 와 동일한 Marginal 을 갖는 ODE 가 존재 (Stochasticity 가 없음)
- Score SDE 논문에선 이 ODE 를 Probability Flow ODE 라고 명명
- 즉, 일반적인 ODE Solver 로 디퓨전 샘플링을 할 수 있음


$$\text{Reverse SDE : } d\mathbf{x} = [\mathbf{f}(\mathbf{x}, t) - g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})] dt + g(t) d\bar{\mathbf{w}}$$

$$\text{PF-ODE : } d\mathbf{x} = [\mathbf{f}(\mathbf{x}, t) - \frac{1}{2} g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})] dt$$

$$\nabla_{\mathbf{x}} \log p_t(\mathbf{x}) = -\epsilon_{\theta} / \sigma_t$$

일반적으로 학습된
디퓨전 모델의 Output

1. 시작 지점을 설정 (x_T)
2. 미분방정식 dx 계산
3. 이 dx 값은 해당 시점의 기울기 (slope)
4. 1 Step 증가: $x_{T-1} = x_T + dx$
5. 반복



Euler Method

SDE/PF-ODE

Score SDEs

❖ Score SDEs

- 놀라운 점은 Diffusion Reverse SDE와 동일한 Marginal 을 갖는 ODE 가 존재 (Stochasticity 가 없음)
- Score SDE 논문에선 이 ODE 를 Probability Flow ODE 라고 명명
- 즉, 일반적인 ODE solver 로 디퓨전 샘플링을 할 수 있음

Reverse SDE : $d\mathbf{x} = [f(\mathbf{x}, t) - \frac{1}{2}g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})]dt$

PF-ODE : $d\mathbf{x} = [f(\mathbf{x}, t) - \frac{1}{2}g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})]dt$

$\nabla_{\mathbf{x}} \log p_t(\mathbf{x}) = -\frac{1}{\sigma(t)^2} \nabla_{\mathbf{x}} \log p_t(\mathbf{x})$

일반적으로 학습된
디퓨전 모델의 Output


**Score SDE 논문은 다른 줄 알았던 두개의 분야
(Diffusion Models, Score – Based Models)
를 하나의 Framework 로 합치고,**

**아무런 관련이 없을 줄 알았던 수치해석학 (ODEs, SDEs) 의
발전을 그대로 적용 할 수 있게 해준 논문!**

1. 시작 지점을 설정 (x_T)
2. 미분방정식 dx 계산
3. 이 dx 값은 해당 시점의 기울기 (slope)

4. 1 Step 증가 : $X_{T-1} = X_T + dx$

5. 반복



VP Formulation

**DDPM,
VDM**

VE Formulation

DSM,NCSN

SDE/PF-ODEs

Score SDE



CM

Consistency Models

Consistency Models

❖ Diffusion / Score based models 의 단점

- Score SDE 의 발견으로 SDE/ODE Solving 을 통한 Few step sampling 으로 이미지를 생성 할 수 있게 됨
- 하지만 SDE/ODE Solving 은 step 수가 작아질 수록 Error 가 증가
- 결국 Quality vs. Sampling speed 의 tradeoff 는 그대로 존재



Consistency Models

❖ PF - ODE Solving and the Denoiser Output

- 일반적인 PF-ODE 를 통한 Sampling 을 다시 살펴보면:

- For Solver Steps, do:

- Denoised output 계산
- Denoised output 을 통해 Score 계산
- Score 을 통해 Derivative 계산
- Solver Step

$$1. D_{\phi}(\mathbf{x}_t, t) = \frac{\mathbf{x}_t - \sigma_t \epsilon_{\theta}(\mathbf{x}_t, t)}{\alpha_t}$$

$$2. s_{\theta}(\mathbf{x}_t) = \frac{\alpha_t D_{\phi}(\mathbf{x}_t, t) - \mathbf{x}_t}{\sigma_t^2} = \frac{-\epsilon_{\theta}(\mathbf{x}_t, t)}{\sigma_t}$$

$$3. \frac{d\mathbf{x}_t}{dt} = f(t)\mathbf{x}_t - \frac{1}{2}g^2(t)\nabla_{\mathbf{x}} \log p(\mathbf{x}_t)$$

$$4. \mathbf{x}_{t-1} = \mathbf{x}_t + \Delta t \frac{d\mathbf{x}_t}{dt} \text{ (Euler Step)}$$



- 이때 Denoised output 이란 모델이 해당 Timestep 에 대해 예측한 Clean Image !
- DDIM 에서도 등장

$$\underbrace{\left(\frac{\mathbf{x}_t - \sqrt{1 - \alpha_t} \epsilon_{\theta}^{(t)}(\mathbf{x}_t)}{\sqrt{\alpha_t}} \right)}_{\text{“predicted } \mathbf{x}_0\text{”}}$$

Consistency Models

❖ PF - ODE Solving and the Denoiser Output


- Denoiser output 에 대한 특징 : Large Timestep 에 대해서는 성능이 낮지만, Small Timesteps 에선 성능이 좋음



Consistency Models

❖ Consistency Models




- Denoiser output 에 대한 특징 : Large Timestep 에 대해서는 성능이 낮지만, Small Timesteps 에선 성능이 좋음
- 이러한 특징을 이용한 것이 Consistency Models : Diffusion Model 이 PF-ODE 를 따라간다는 점과 Denoiser Output 또한 구할 수 있다는 점을 활용
기존 모델을 Distillation 하는 방법론 : 1 Step Generation
- 동일한 PF-ODE 위 adjacent RV 의 Denoiser Output 이 가까워 지도록 학습



Consistency Models

❖ Consistency Models : Consistency Distillation



- 먼저 Training 이미지를 Forward Process 를 통해 x_t 까지 Noise
- Teacher Model 이 x_t 에서 One step PF-ODE Solving 진행 : x_{t-1}^ϕ
- Student Model 은 두 RV 에 대한 Denoiser output 예측
- 두 Denoiser Output 에 대한 distance 를 최소화 하도록 Student Model 학습
- 즉, 어느 시점에서 Denoiser output 을 구해도 잘 생성하도록 학습하는 것




Consistency Models

❖ Consistency Models : Consistency Distillation

- 학습이 완료된 Consistency Model 은 1 Step Generation 을 수행 할 수 있게 됨
- PF-ODE Trajectory 위 어떤 Random Variable 의 Denoiser Output 이 성능이 좋기 때문



CM 1 Step



Conclusion

❖ VP, VE Formulation

- VP, VE Formulation 의 차이, 기원
- Diffusion Models 와 Score Based Models 의 관계

❖ Score SDE

- Diffusion Models 와 Score Based Models 의 Unified Framework
- SDEs, PF-ODEs

❖ Consistency Models

- PF-ODE 와 Denoiser 를 활용한 1 Step Generation 방법론



“Photorealistic image of a cute cat wearing a bachelor's cap, holding a sign that says 'Thank You!'”