

# Diffusion-based Anomaly Detection



안시후

2024.01.12

# 발표자 소개



## ❖ 안시후 (Sihu Ahn)

- Data Mining & Quality Analytics Lab (김성범 교수님)
- Ph.D. Student (2021.3 ~)

## ❖ 관심 연구 분야

- Diffusion models
- Computer Vision (Human Action Recognition)

## ❖ E-mail

- [sihuahn@korea.ac.kr](mailto:sihuahn@korea.ac.kr)

# CONTENTS

## 1. Introduction

- Anomaly Detection
- Diffusion models

## 2. Diffusion-based Anomaly Detection models

- AnoDDPM
- DiffAD
- MoCoDAD

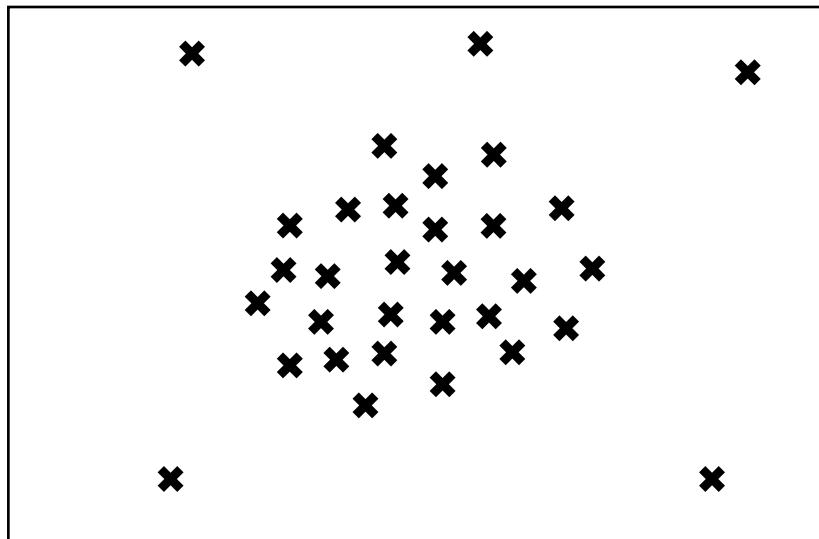
## 3. Conclusion

# 1. Introduction

---

## ❖ Anomaly Detection (이상치 탐지)

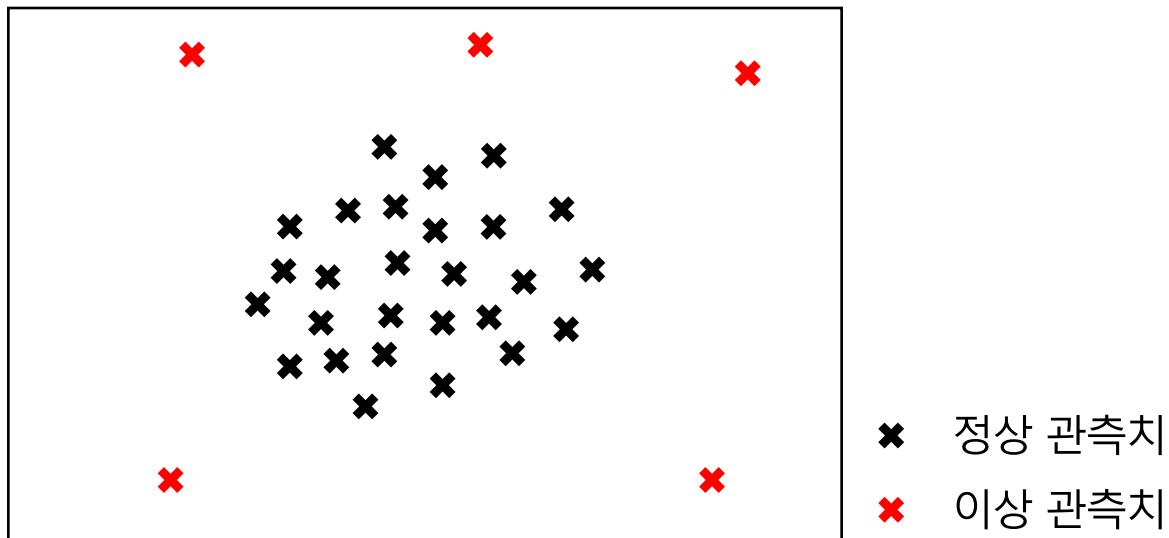
- 이상치는 대부분의 데이터와 본질적인 특성이 다른 관측치를 의미



# 1. Introduction

## ❖ Anomaly Detection (이상치 탐지)

- 이상치는 대부분의 데이터와 본질적인 특성이 다른 관측치를 의미

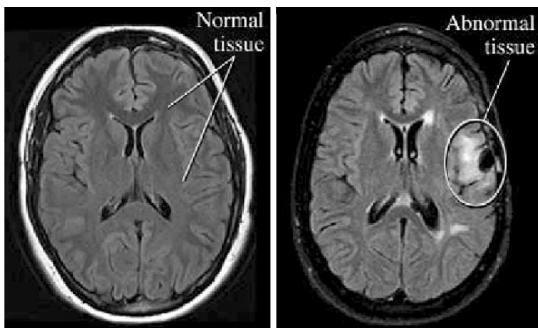


# 1. Introduction

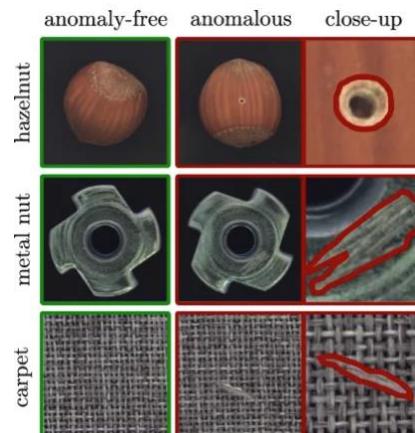
## ❖ Anomaly Detection (이상치 탐지)

- 이상치는 대부분의 데이터와 본질적인 특성이 다른 관측치를 의미
- 현실에서는 다양한 이상치가 존재
- 대부분의 데이터가 정상인 경우 이상치 탐지를 적용

의료 이상치 탐지



산업 이상치 탐지



감시 카메라 이상치 탐지



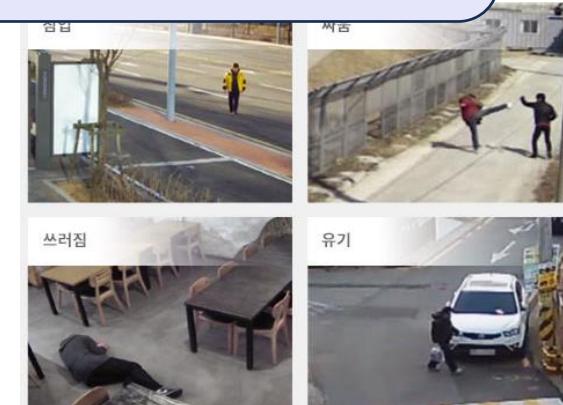
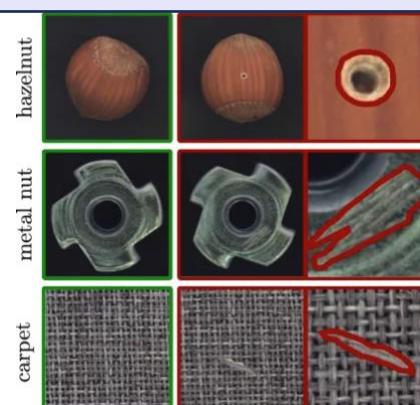
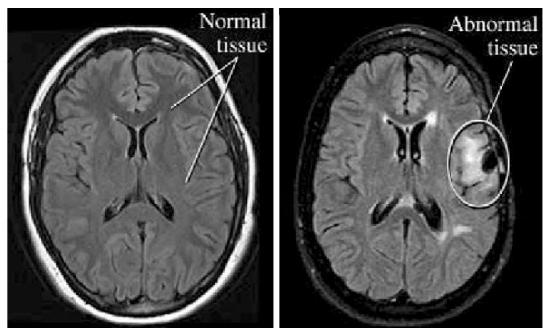
# 1. Introduction

## ❖ Anomaly Detection (이상치 탐지)

- 이상치는 대부분의 데이터와 본질적인 특성이 다른 관측치를 의미
- 현실에서는 다양한 이상치가 존재
- 대부분의 데이터가 정상인 경우 이상치 탐지를 적용

의료

왜 이진 분류를 사용하지 않고 이상치 탐지를 사용하는가?

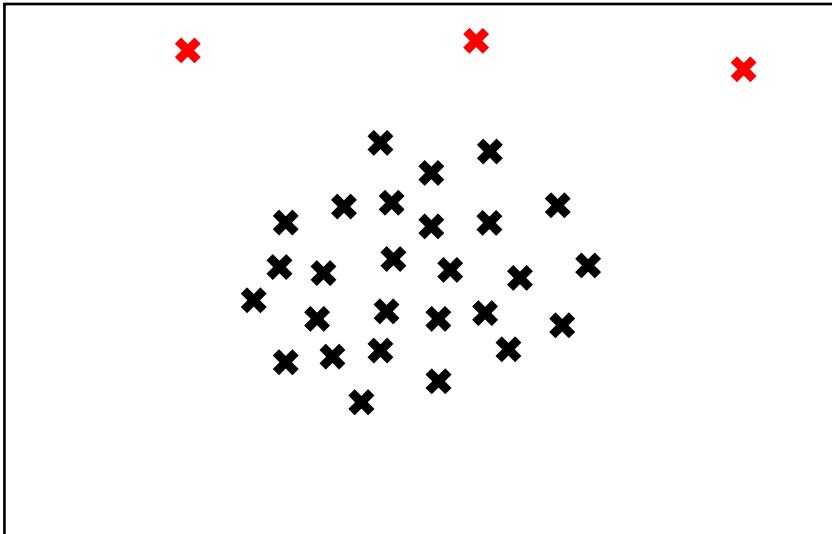


# 1. Introduction

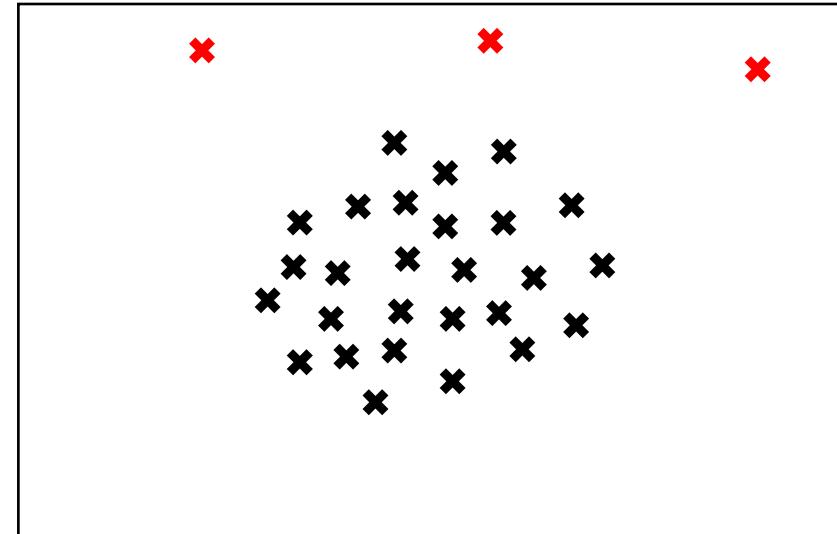
## ❖ Anomaly Detection (이상치 탐지)

- 분류와 이상치 탐지의 차이

분류 예시



이상치 탐지 예시



✖ 정상 관측치

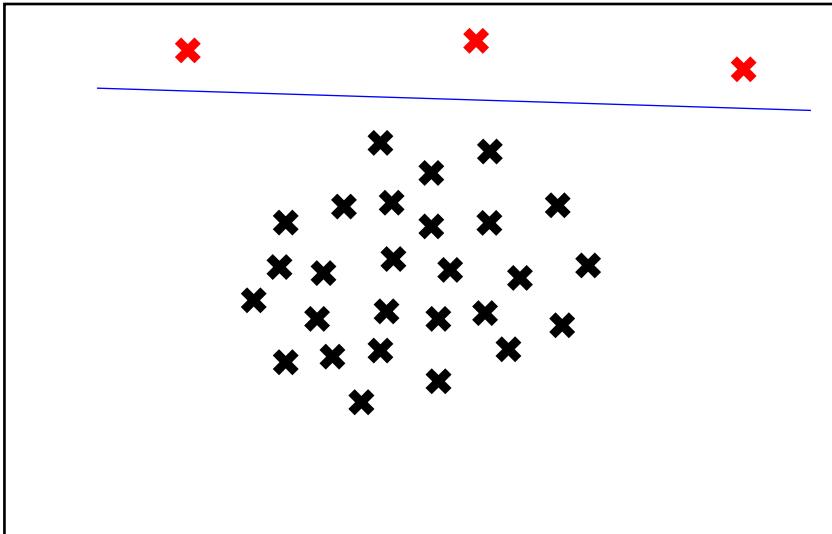
✖ 이상 관측치

# 1. Introduction

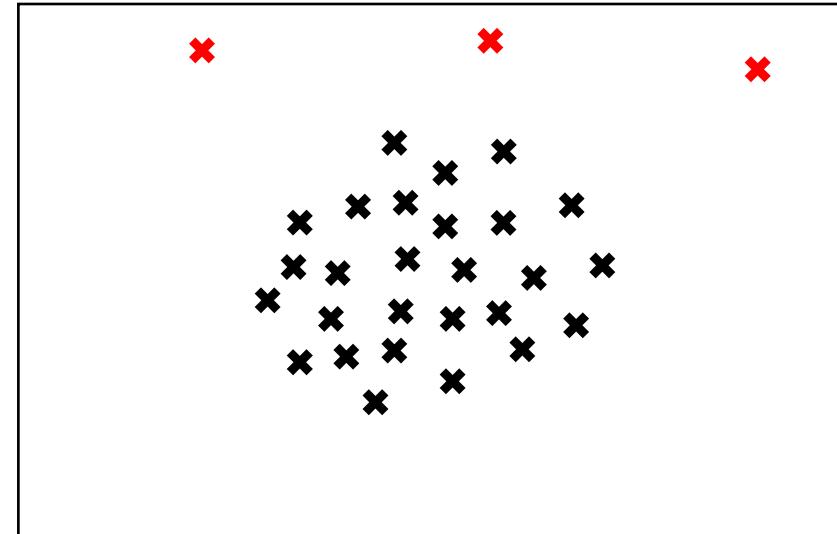
## ❖ Anomaly Detection (이상치 탐지)

- 분류와 이상치 탐지의 차이

분류 예시



이상치 탐지 예시



✖ 정상 관측치

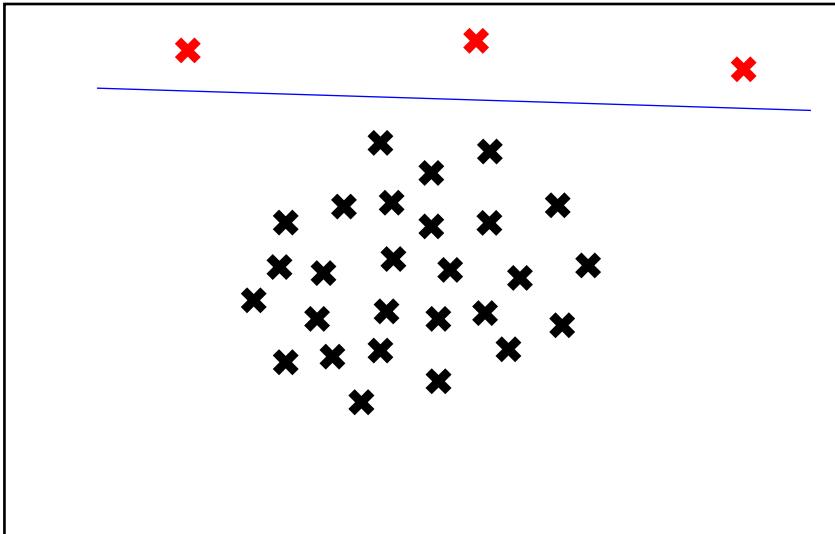
✖ 이상 관측치

# 1. Introduction

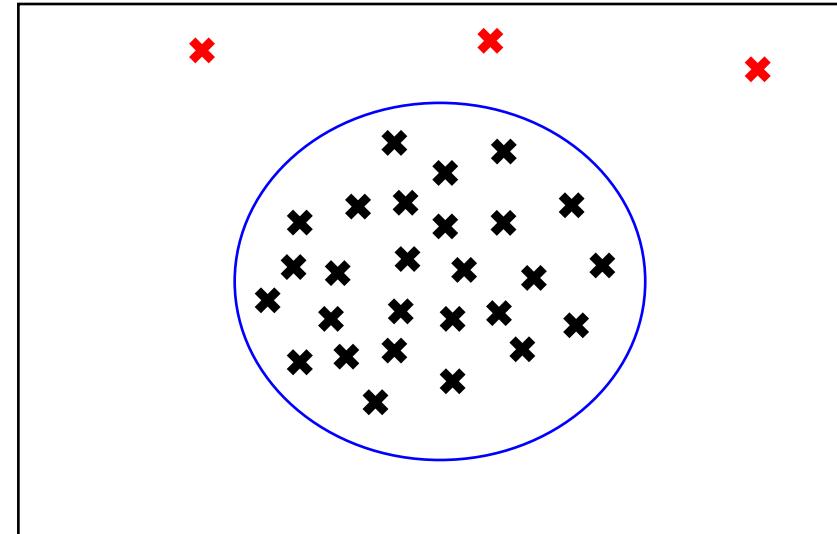
## ❖ Anomaly Detection (이상치 탐지)

- 분류와 이상치 탐지의 차이

분류 예시



이상치 탐지 예시



✖ 정상 관측치

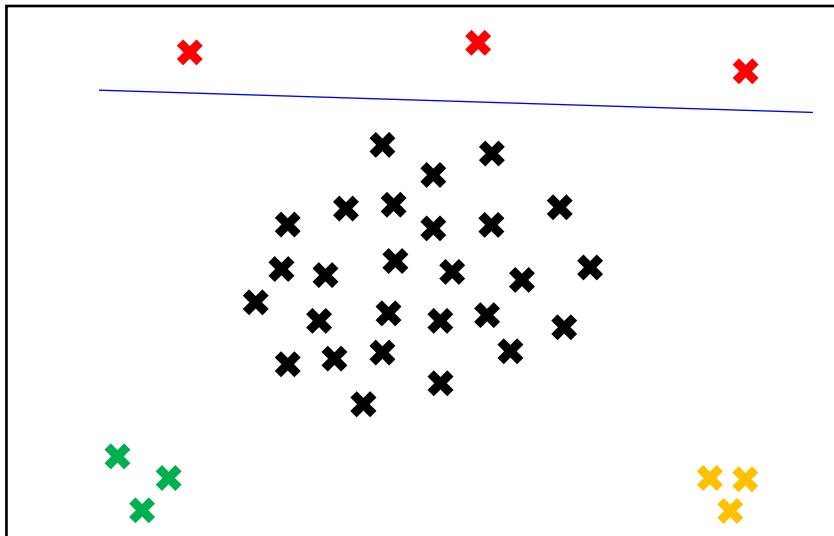
✖ 이상 관측치

# 1. Introduction

## ❖ Anomaly Detection (이상치 탐지)

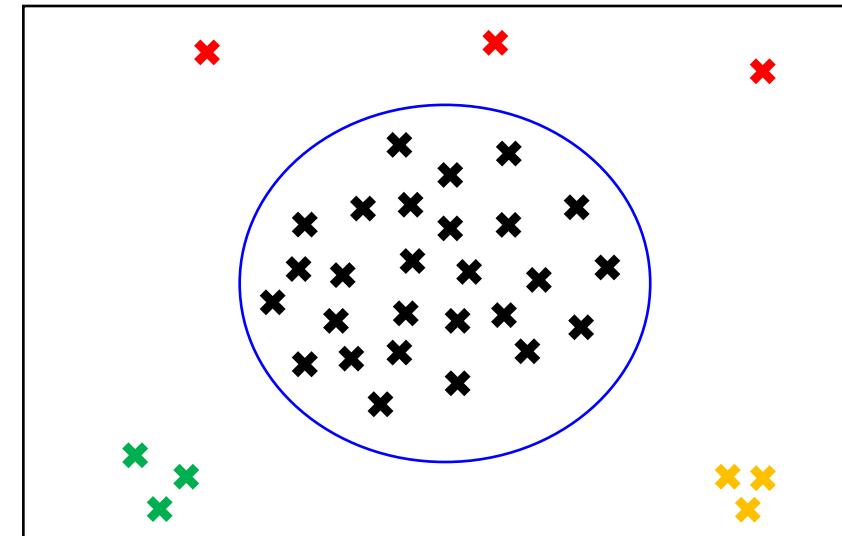
- 분류와 이상치 탐지의 차이
  - 정상에 비해 이상치는 다양한 케이스가 존재하기 때문에 분류가 어려울 수 있음

분류 예시



✖ 정상 관측치

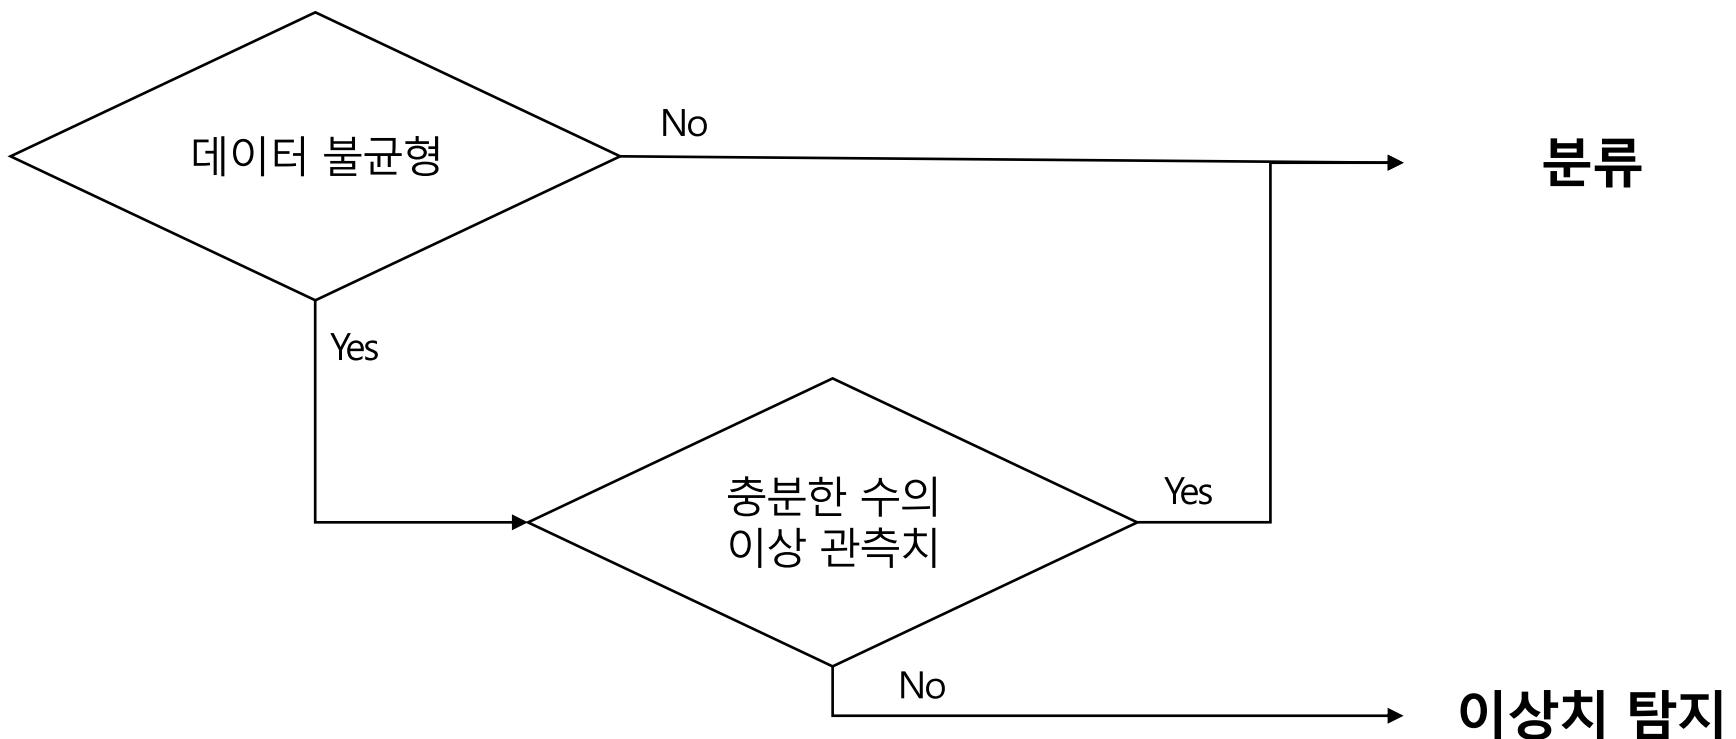
이상치 탐지 예시



# 1. Introduction

## ❖ Anomaly Detection (이상치 탐지)

- 분류와 이상치 탐지의 차이
- 충분한 수의 이상치 데이터가 존재한다면 분류 문제로 접근 가능

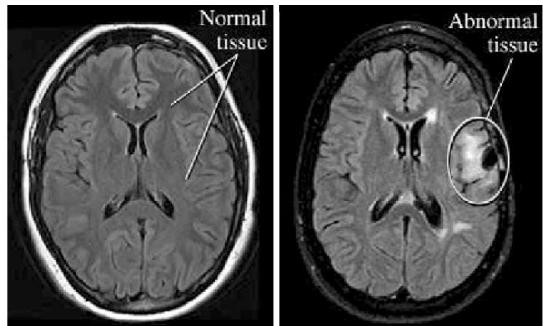


# 1. Introduction

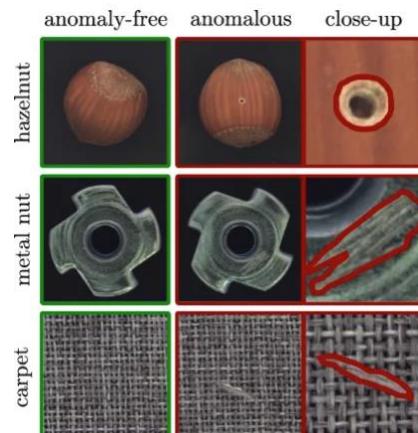
## ❖ Anomaly Detection (이상치 탐지)

- 충분한 수의 이상치 데이터가 존재한다면 분류 문제로 접근 가능
- 현실 문제에서는 충분한 수의 이상치가 존재하지 않는 경우가 대부분  
> 다양한 이상치를 분류하는 것 보다 이상치 탐지 방법으로 접근하는 것이 합리적

의료 이상치 탐지



산업 이상치 탐지



감시 카메라 이상치 탐지

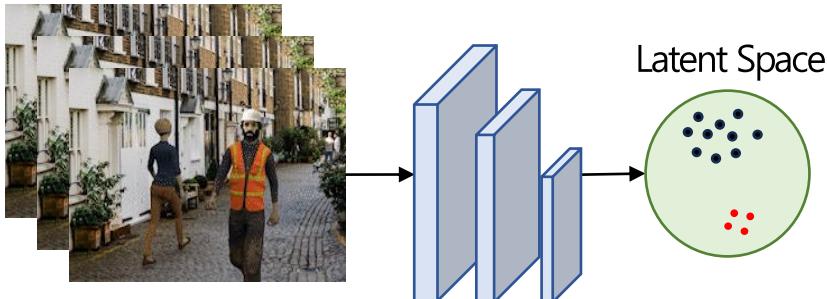


# 1. Introduction

## ❖ Anomaly Detection (이상치 탐지)

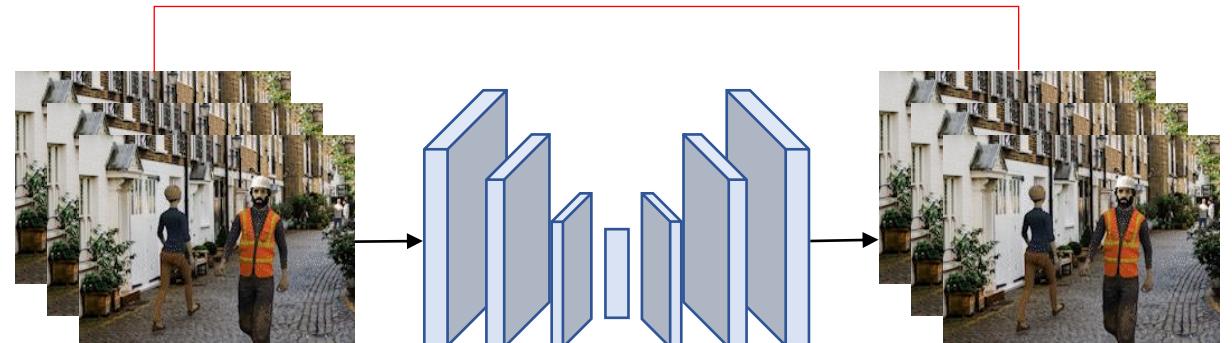
- 통계나 시각화를 통한 이상치 탐지도 가능하지만  
잠재 기반 혹은 재구축 기반의 딥러닝 방법론 등이 활발히 연구 중

잠재 기반 이상치 탐지



재구축 기반 이상치 탐지

Reconstruction error



# 1. Introduction

## ❖ Anomaly Detection (이상치 탐지)

- 통계나 시각화를 통한 이상치 탐지도 가능하지만  
잠재 기반 혹은 재구축 기반의 딥러닝 방법론 등이 활발히 연구 중
- 재구축 기반 이상치 탐지는 생성모델 기반 GAN, VAE, Diffusion models가 사용되고 있다

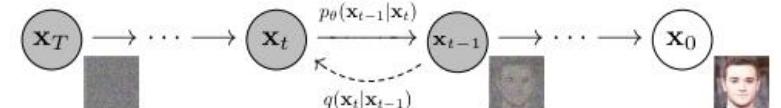
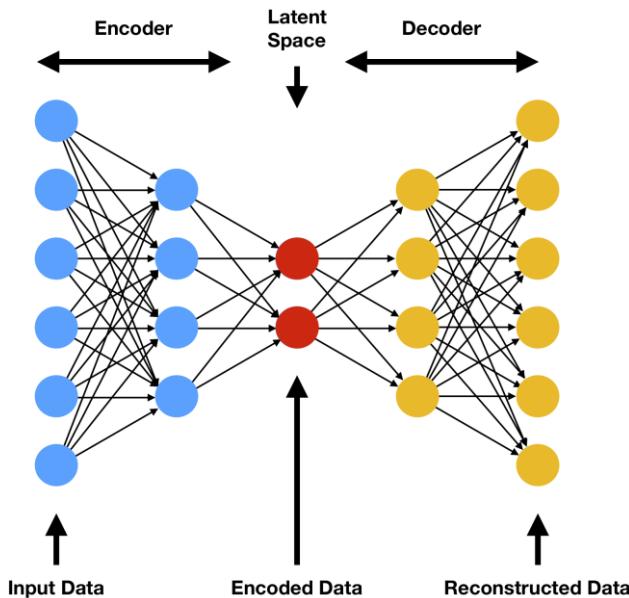
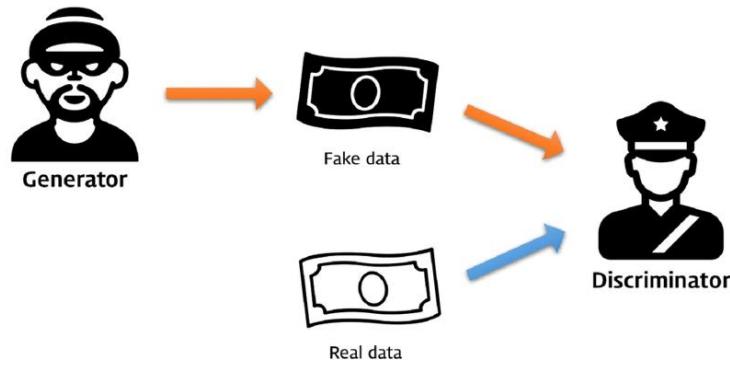
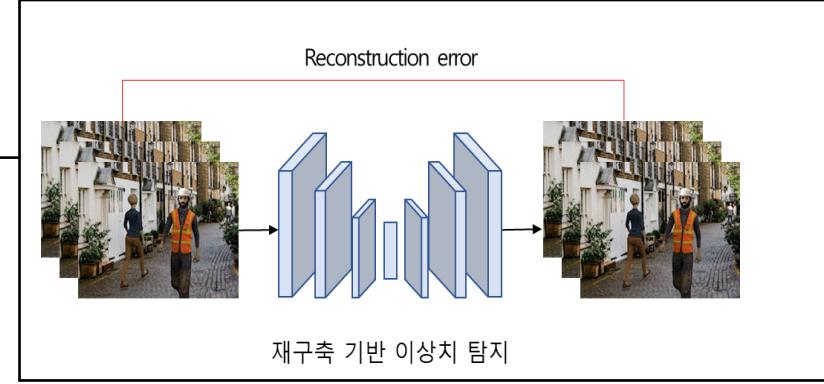
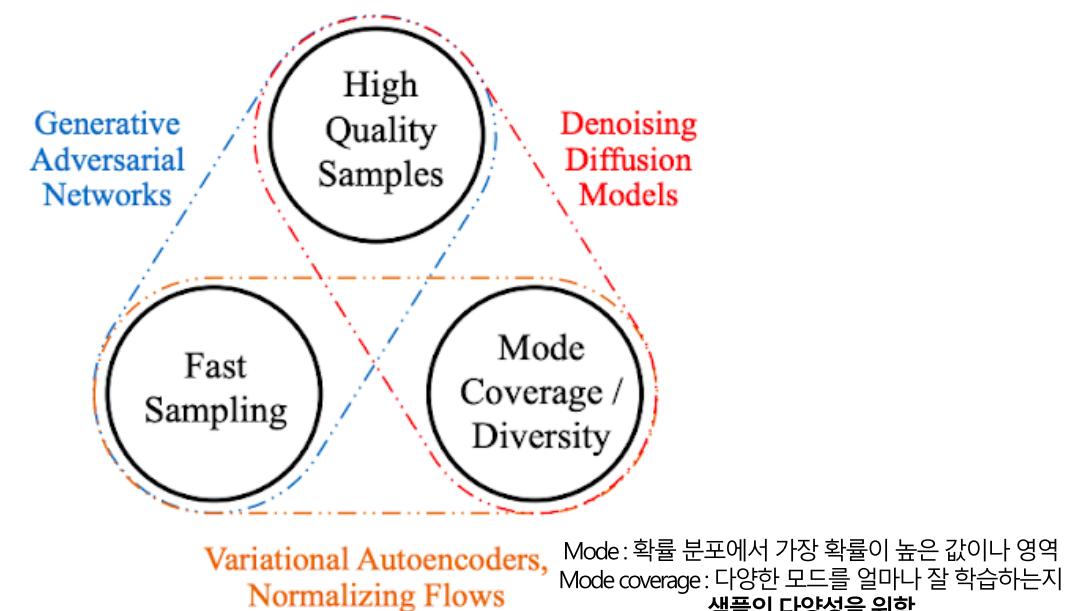
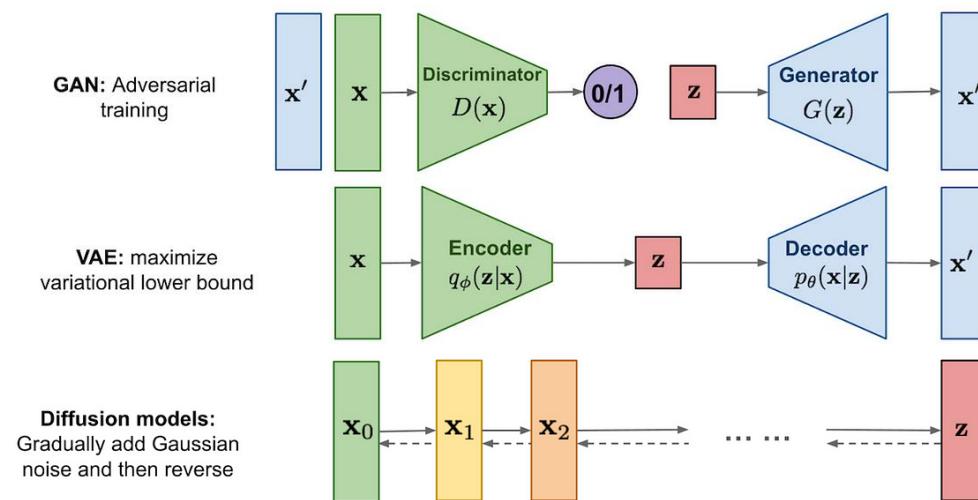


Figure 2: The directed graphical model considered in this work.

# 1. Introduction

## ❖ Diffusion models

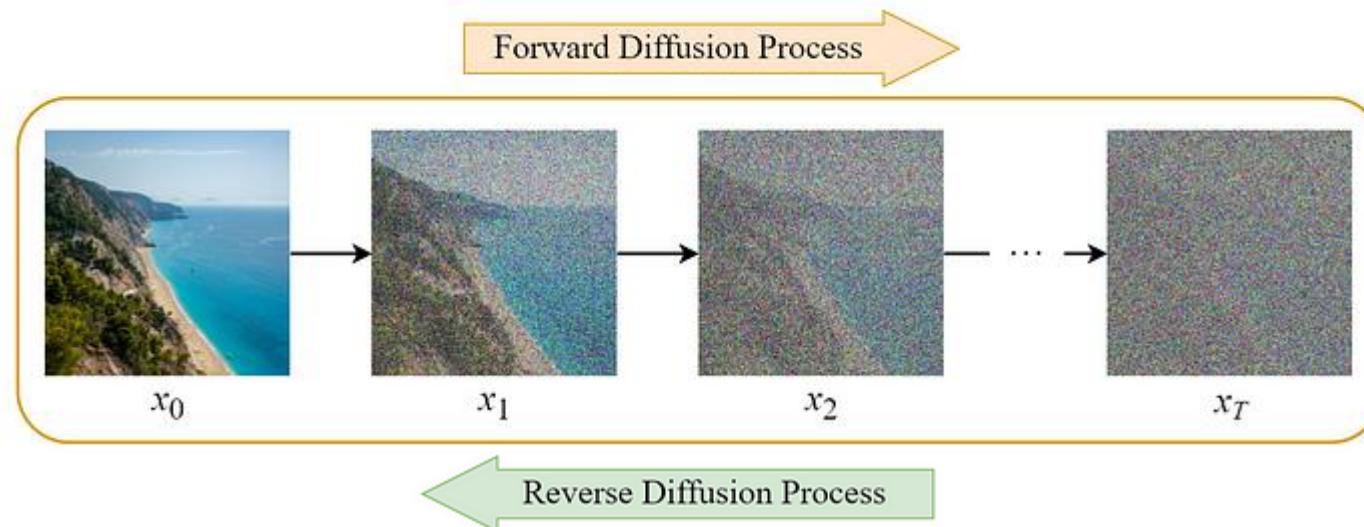
- GAN은 2개의 네트워크로 구성되어 hyperparameter에 민감하여 다양한 샘플 생성이 어려움
- VAE는 생성 되는 이미지가 흐릿하게 생성되어 퀄리티가 떨어짐
- 높은 퀄리티와 다양한 샘플을 가질 수 있는 Diffusion models
  - 최근에는 빠르게 샘플링 하는 연구도 이루어지고 있음



# 1. Introduction

## ❖ Diffusion models

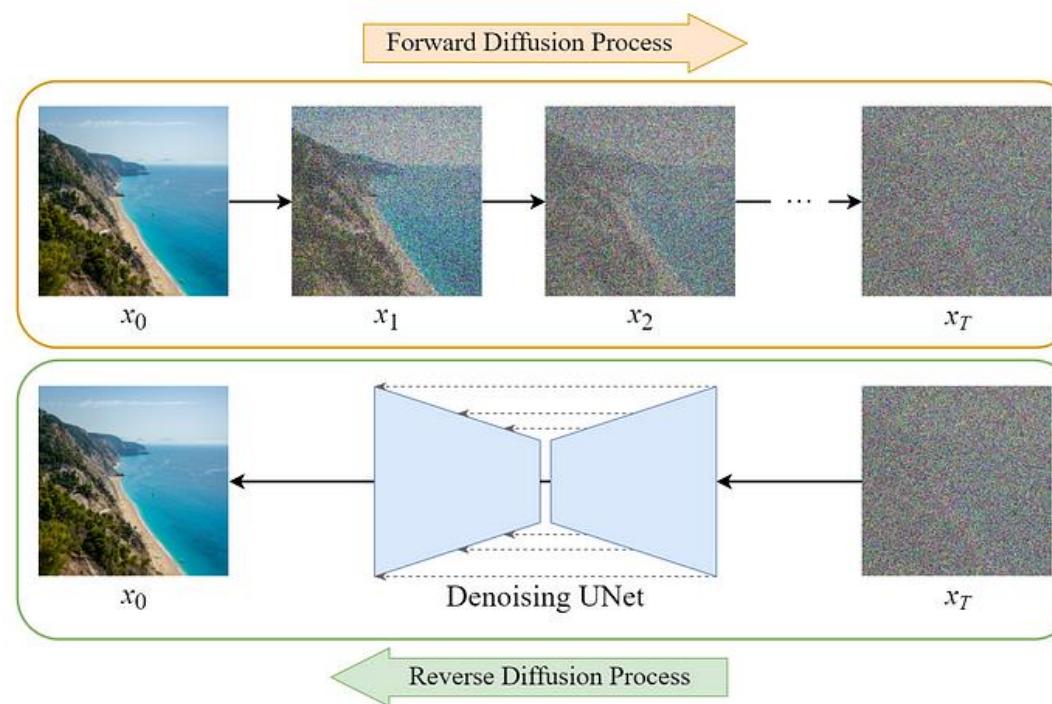
- Forward Diffusion Process: 데이터( $x_0$ )가 완전한 Noise( $x_T$ )가 될 때까지 Noise를 점진적으로 추가
- Reverse Diffusion Process: 완전한 Noise( $x_T$ )에서 점진적으로 Noise를 제거하여 데이터( $x_0$ )를 복원



# 1. Introduction

## ❖ Diffusion models

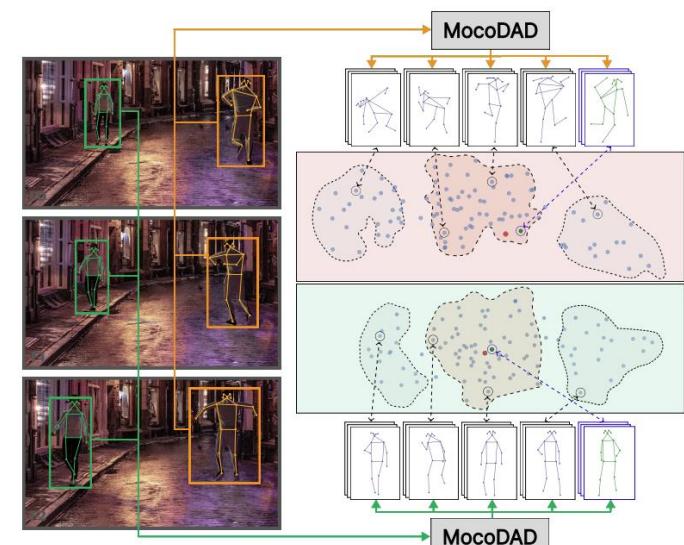
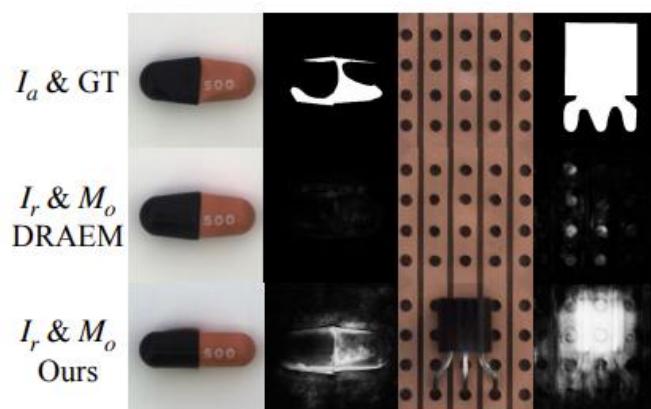
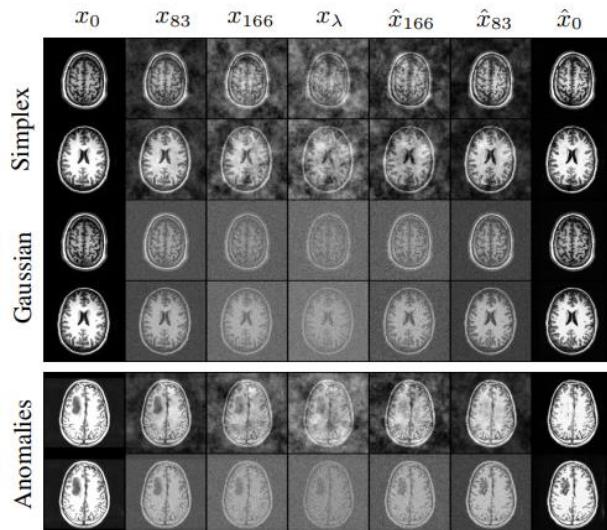
- Forward Diffusion Process: 데이터( $x_0$ )가 완전한 Noise( $x_T$ )가 될 때까지 Noise를 점진적으로 추가
  - 노이즈를 주는 과정은 단순하기 때문에 랜덤으로 노이즈를 적용
- Reverse Diffusion Process: 완전한 Noise( $x_T$ )에서 점진적으로 Noise를 제거하여 데이터( $x_0$ )를 복원
  - 복원 과정은 단순하지 않기 때문에 딥러닝 모델을 활용



## 2. Diffusion-based Anomaly Detection models

### ❖ Diffusion models

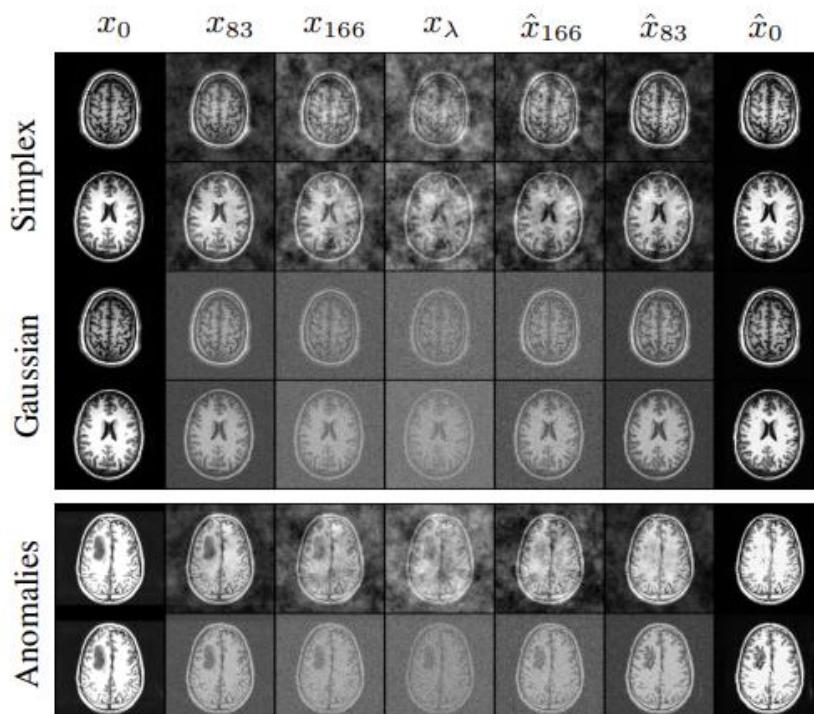
- 뇌에 악성 종양이 있는지 판단하는 AnoDDPM
- 품질 검사 라인에서 이상치 탐지를 수행하는 DiffAD
- 동영상으로부터 사람의 이상 행동을 탐지하는 MoCoDAD



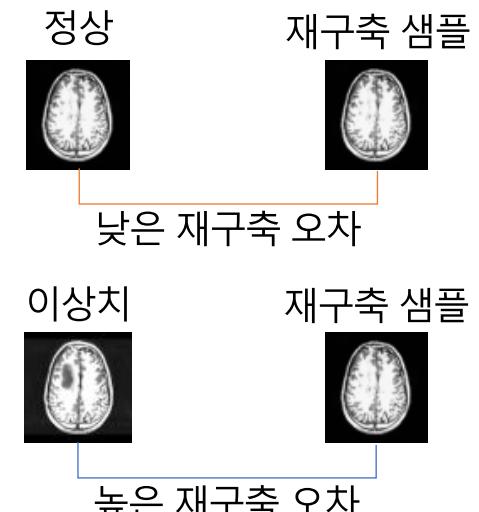
## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)
  - ▶ 뇌에 악성 종양이 있는지 판단하는 Anomaly Detection 수행
  - ▶ Partial Diffusion strategy 및 Multi-scale Simplex Noise 사용



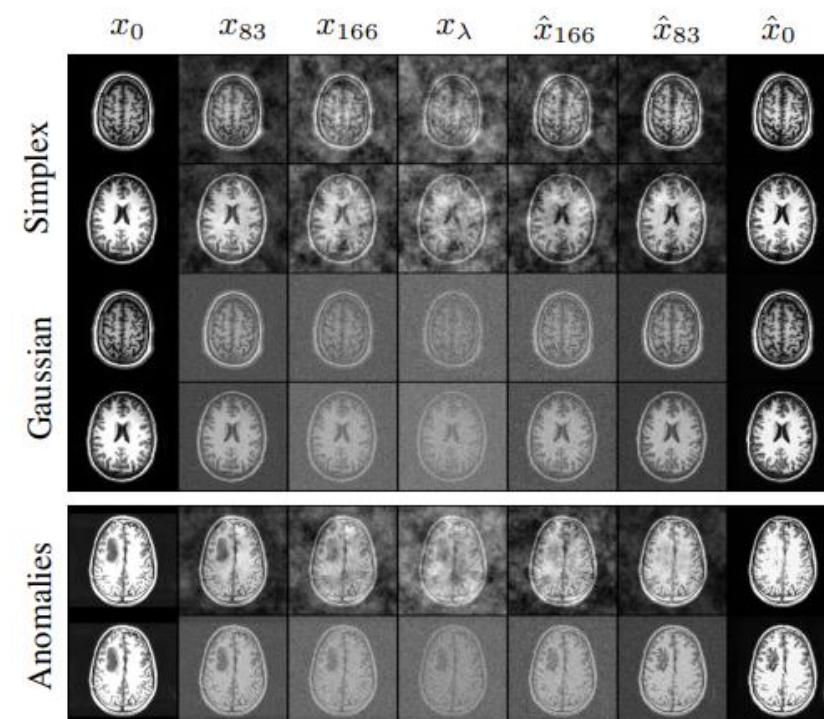
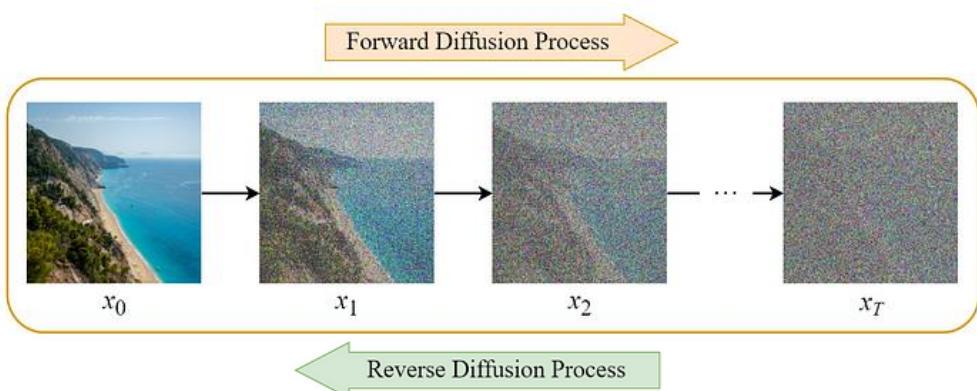
연구 목표



## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

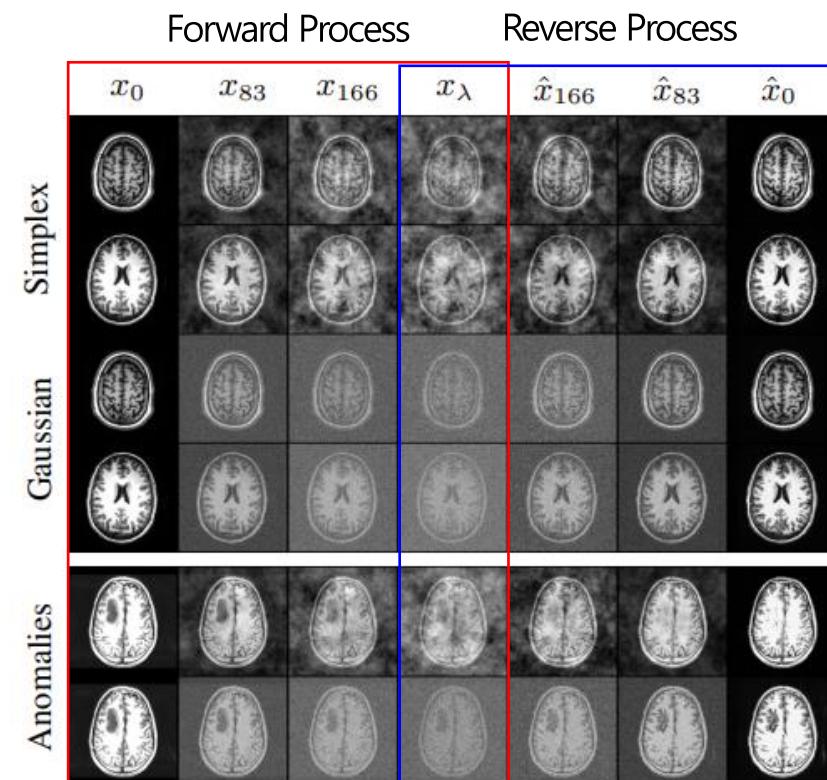
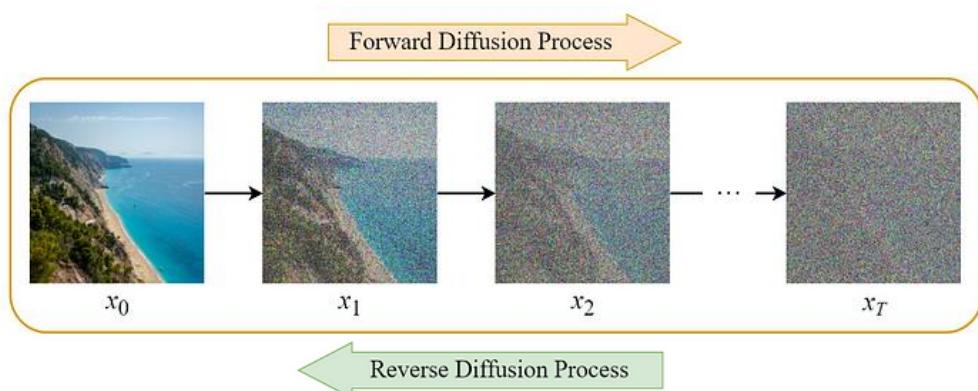
- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)
  - ▶ 뇌에 악성 종양이 있는지 판단하는 Anomaly Detection 수행
  - ▶ Partial Diffusion strategy 및 Multi-scale Simplex Noise 사용



## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

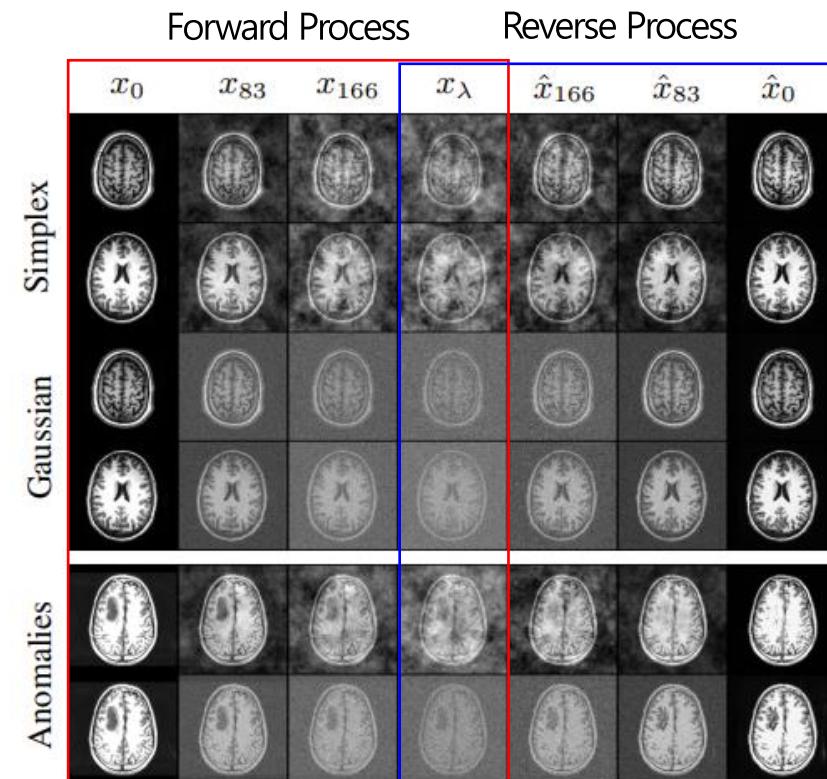
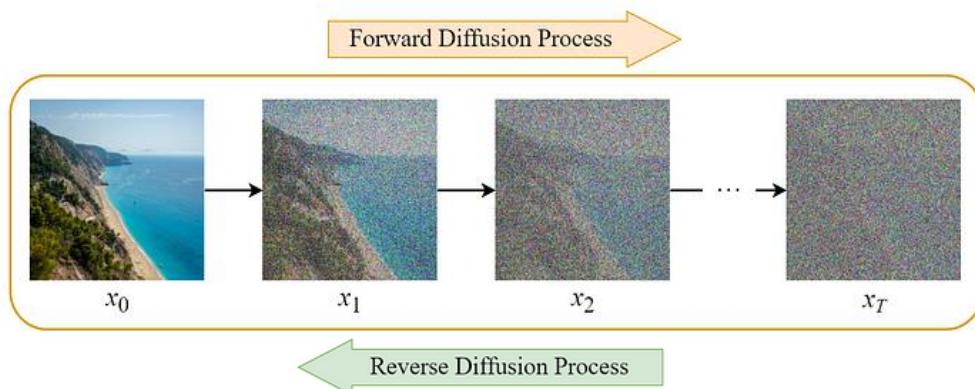
- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)
  - ▶ 뇌에 악성 종양이 있는지 판단하는 Anomaly Detection 수행
  - ▶ Partial Diffusion strategy 및 Multi-scale Simplex Noise 사용



## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)
  - Partial Diffusion strategy : 기존 하나의 시점마다 연산해주던 부분을 T 시점에 해당하는  $\lambda$ 에 3번 만에 도달할 수 있도록 사용

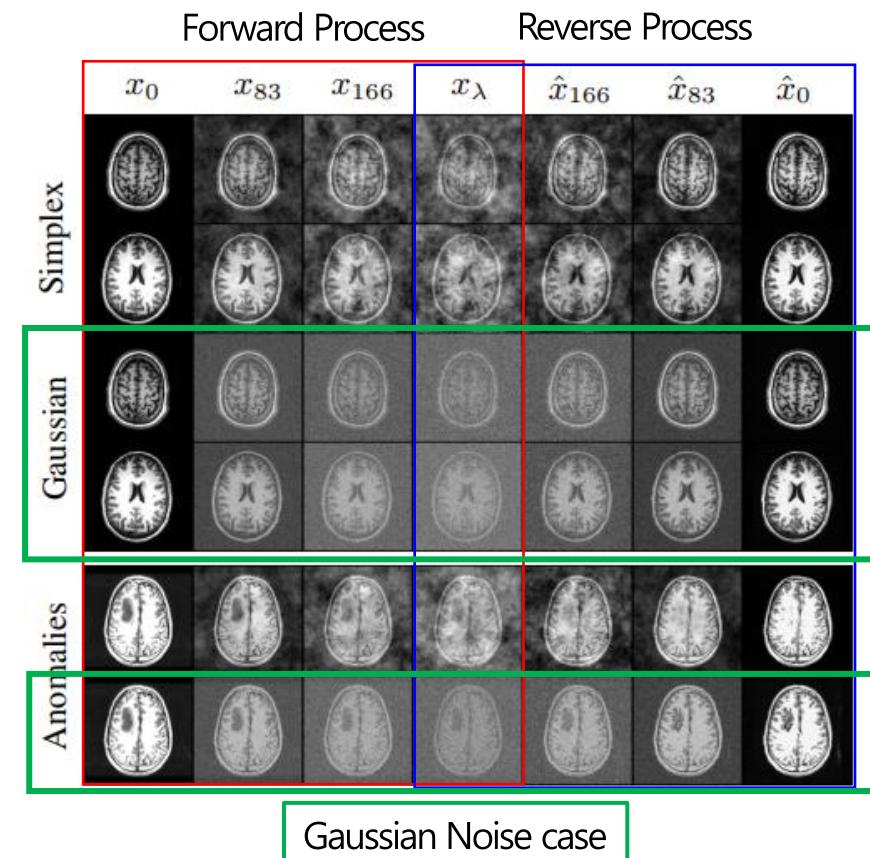
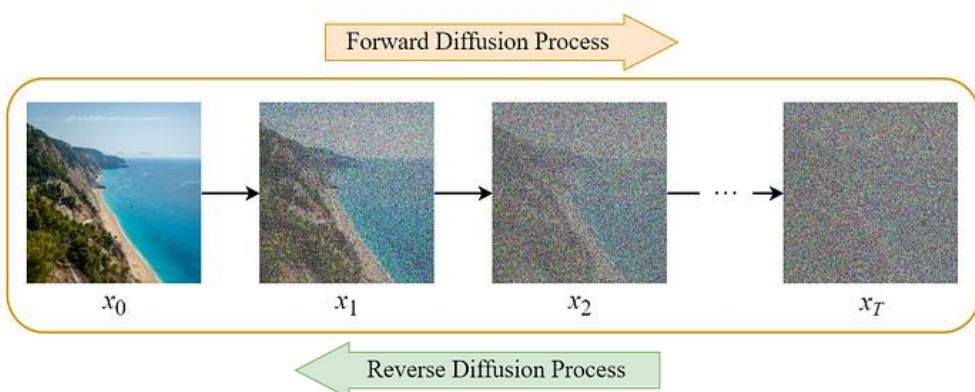


## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)

➤ Gaussian Noise 균일한 노이즈를 주게 되어 이상치를 그대로 생성해내는 현상 발견

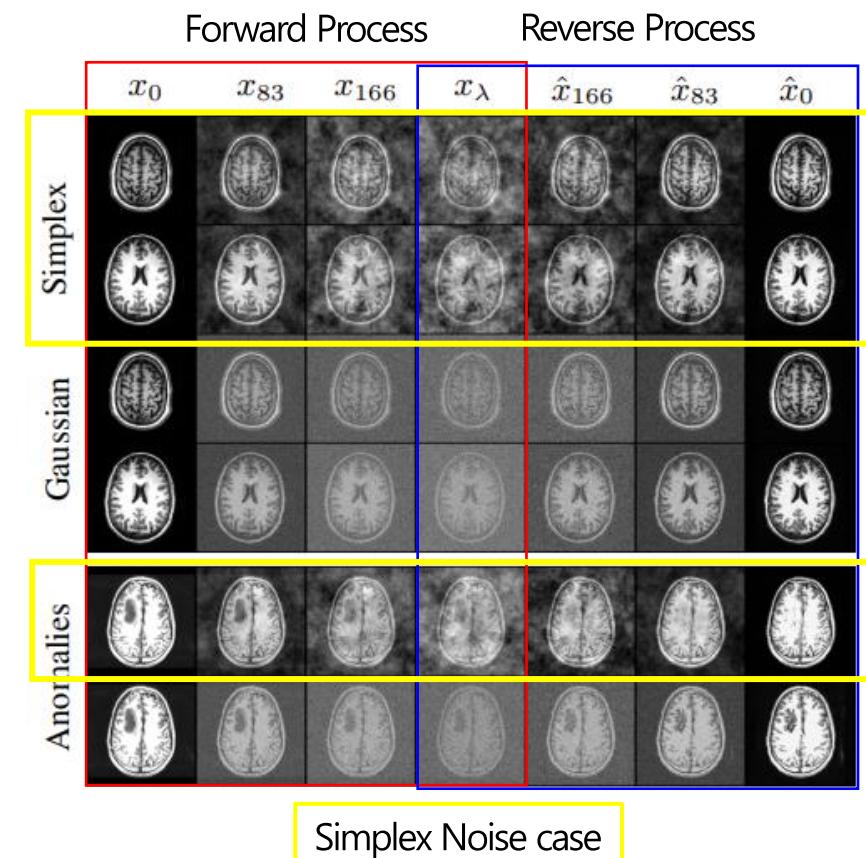
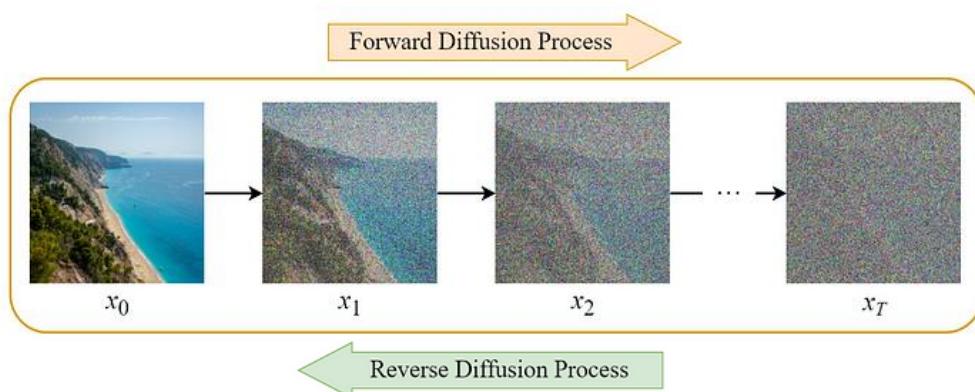


## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)

- Gaussian Noise 균일한 노이즈를 주게 되어 이상치를 그대로 생성해내는 현상 발견
- 자연스러운 노이즈 패턴을 생성해주는 Simplex Noise 사용



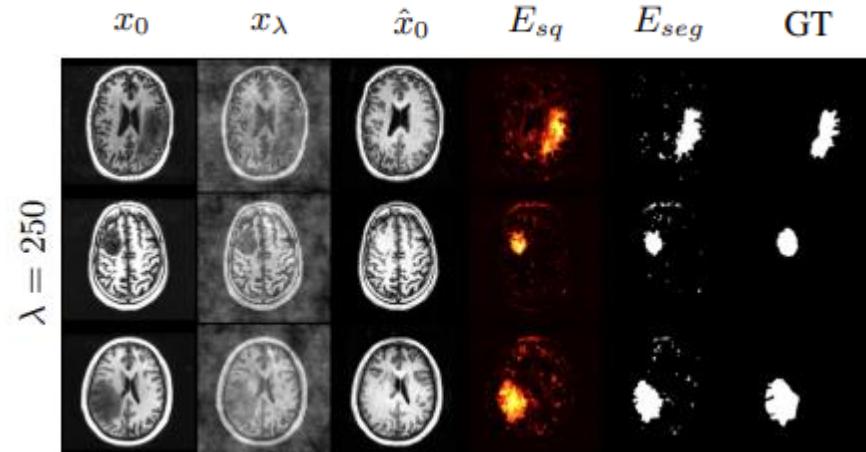
## 2. Diffusion-based Anomaly Detection models

### ❖ AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise

- Diffusion을 Anomaly Detection에 적용한 AnoDDPM 모델 (CVPR 2022)

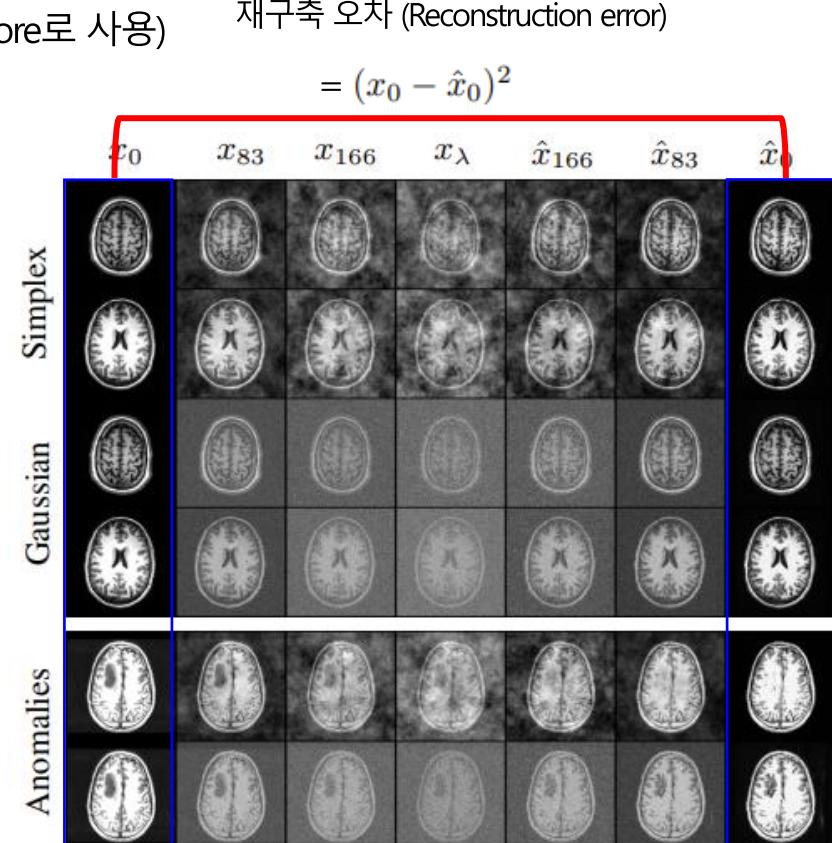
➤ Segmentation 평가 지표인 Dice, IoU와 분류 평가 지표인 AUC를 통해 성능 비교

(Reconstruction Error : input과 output을 square error로 비교 및 anomaly score로 사용)



재구축 오차 (Reconstruction error)

$$= (x_0 - \hat{x}_0)^2$$

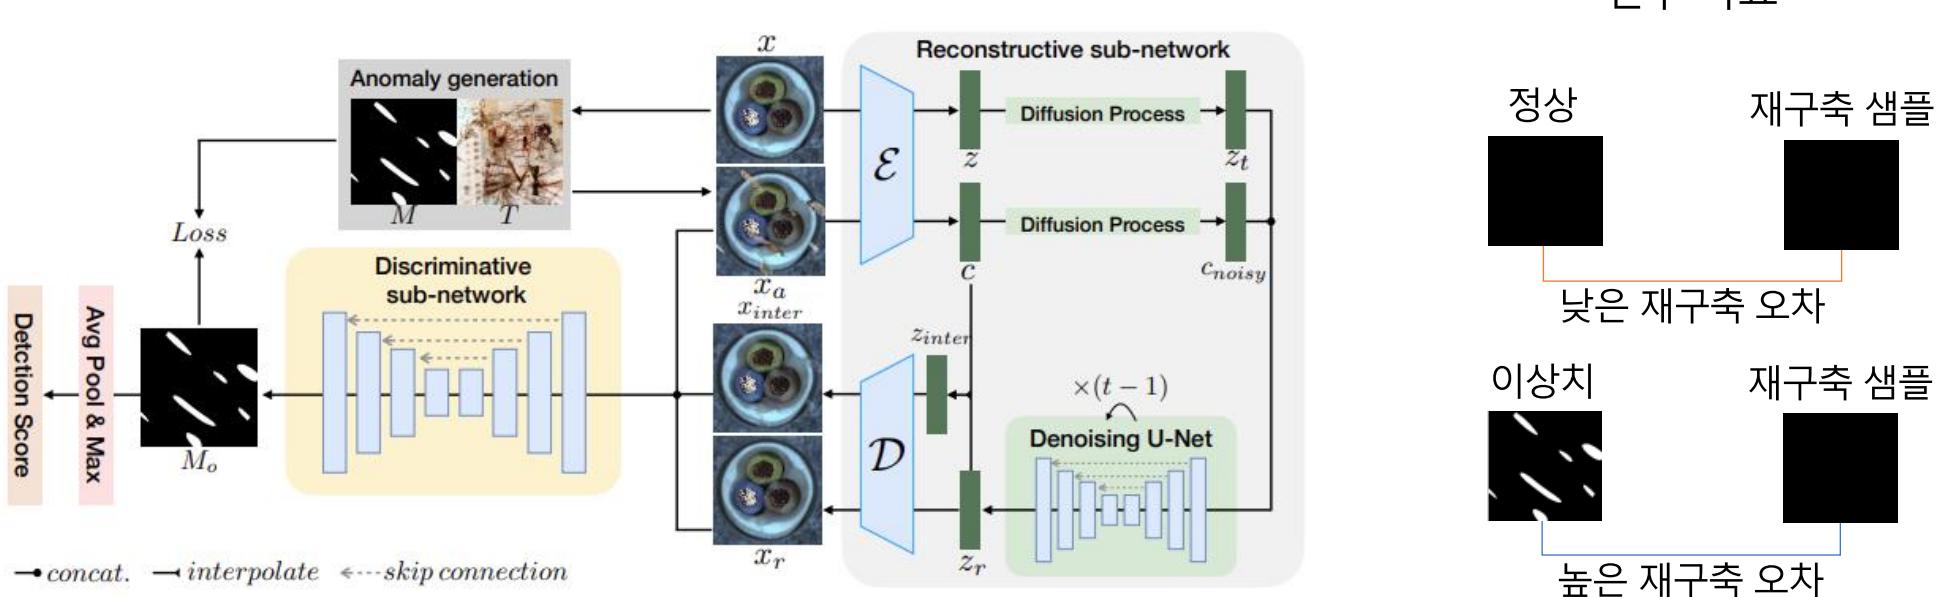


	Dice ↑	IoU ↑	Precision ↑	Recall ↑	AUC ↑
Context Encoder [12]	$0.252 \pm 0.209$	$0.162 \pm 0.149$	$0.258 \pm 0.223$	$0.279 \pm 0.234$	$0.707 \pm 0.150$
f-AnoGAN [20]	$0.128 \pm 0.001$	$0.093 \pm 0.003$	$0.362 \pm 0.009$	$0.080 \pm 0.003$	$0.789 \pm 0.001$
AnoDDPM - Gauss (Ours)	$0.009 \pm 0.012$	$0.004 \pm 0.006$	$0.006 \pm 0.009$	$0.032 \pm 0.044$	$0.601 \pm 0.074$
AnoDDPM $\mathcal{L}_s$ (Ours)	<b><math>0.383 \pm 0.258</math></b>	<b><math>0.269 \pm 0.204</math></b>	<b><math>0.373 \pm 0.269</math></b>	<b><math>0.468 \pm 0.283</math></b>	<b><math>0.863 \pm 0.107</math></b>

## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

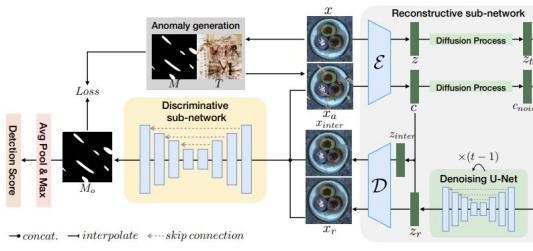
- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용



## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용



입력 이미지



$M$



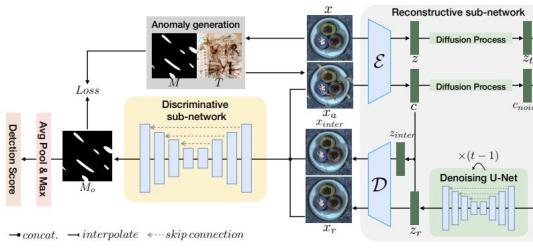
$T$

랜덤 노이즈, 표면 소스 이미지

## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

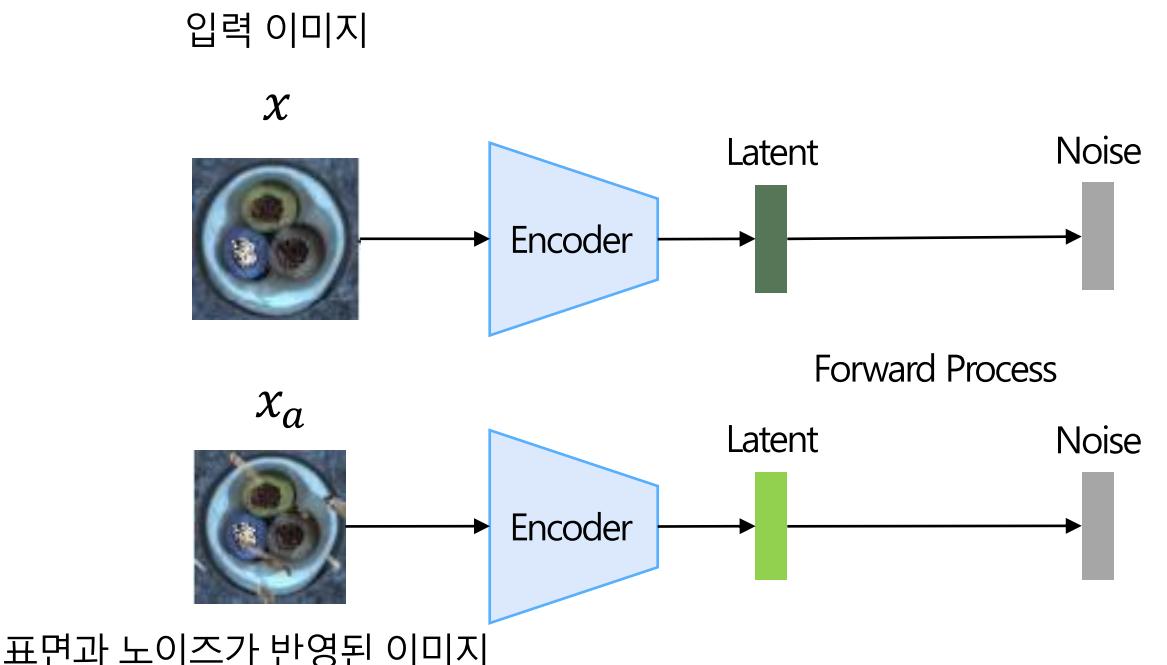
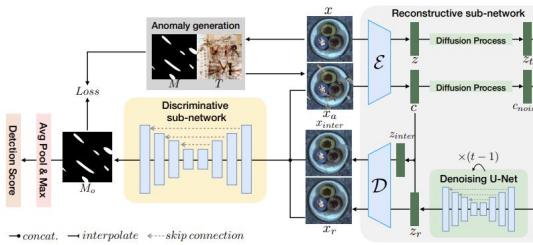
- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용



## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

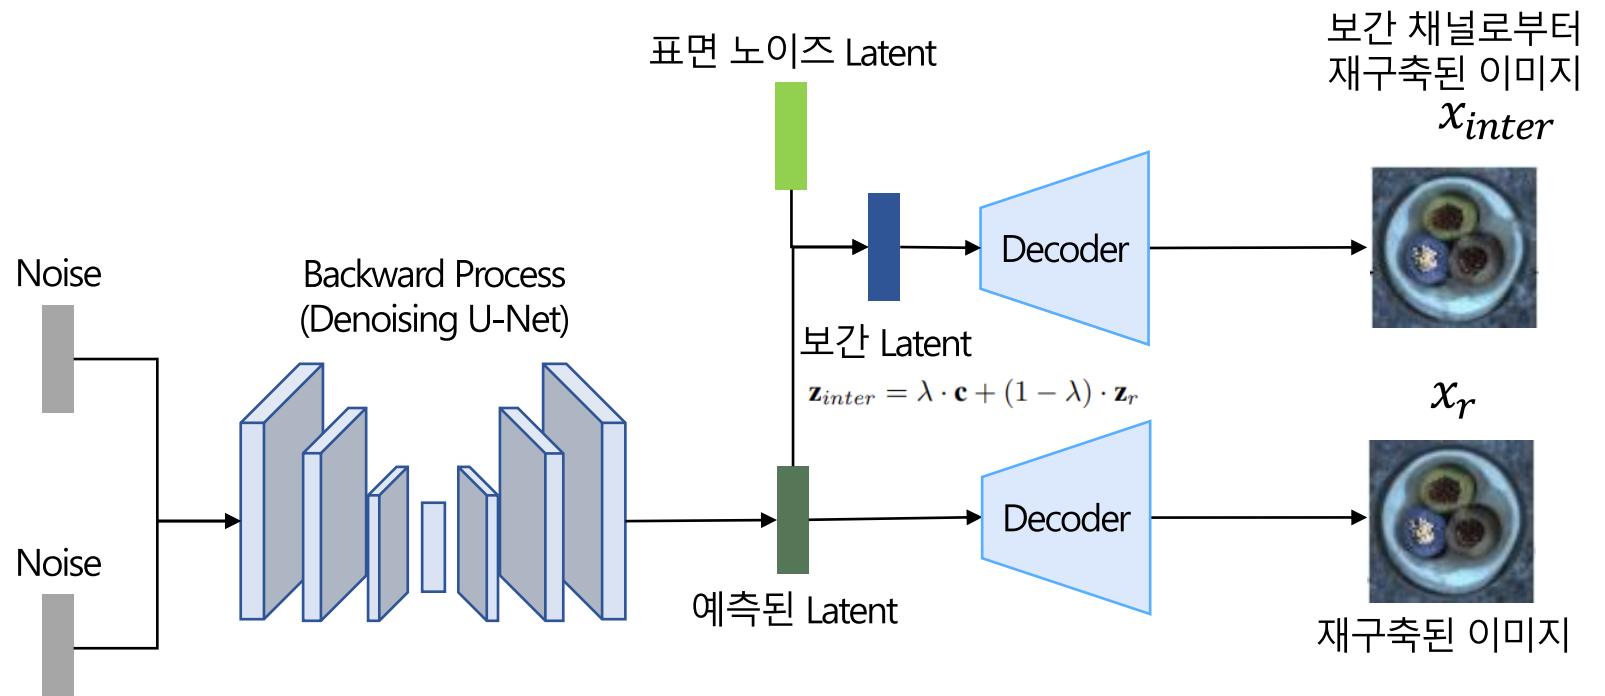
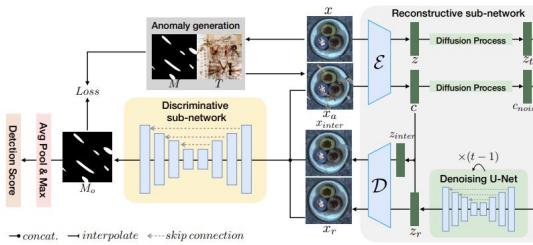
- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용



## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용



## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용

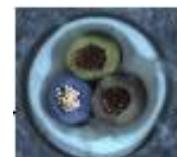
표면과 노이즈가 반영된 이미지

$x_a$



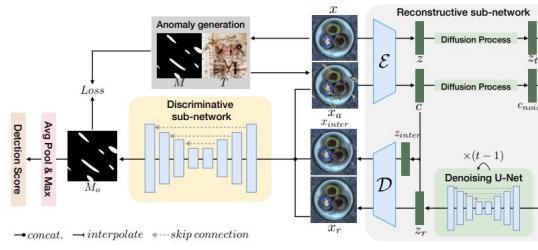
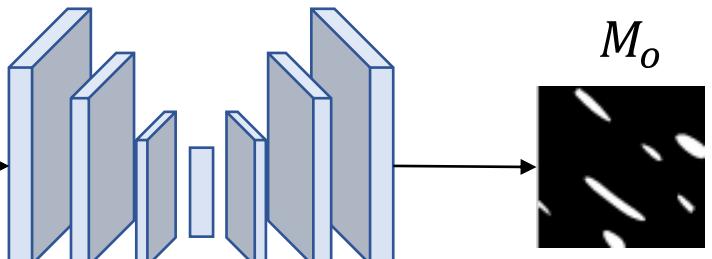
보간 채널로부터 재구축된 이미지

$x_{inter}$



재구축된 이미지

$x_r$



## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용

표면과 노이즈가 반영된 이미지

$x_a$



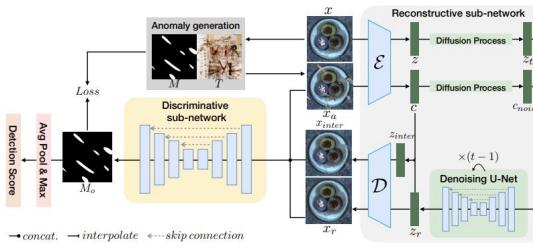
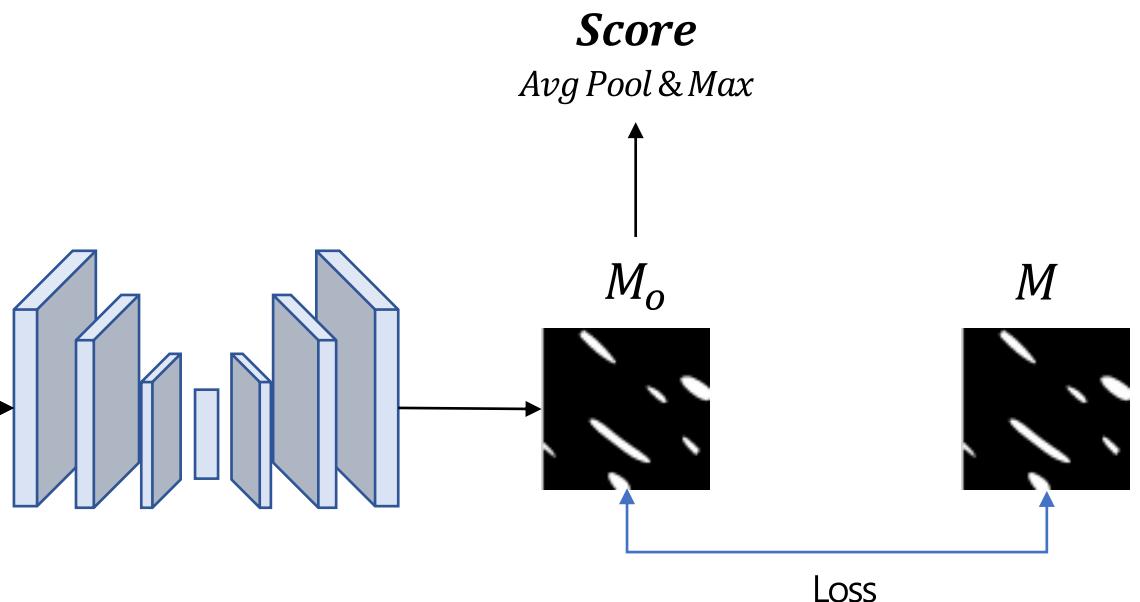
보간 채널로부터 재구축된 이미지

$x_{inter}$



재구축된 이미지

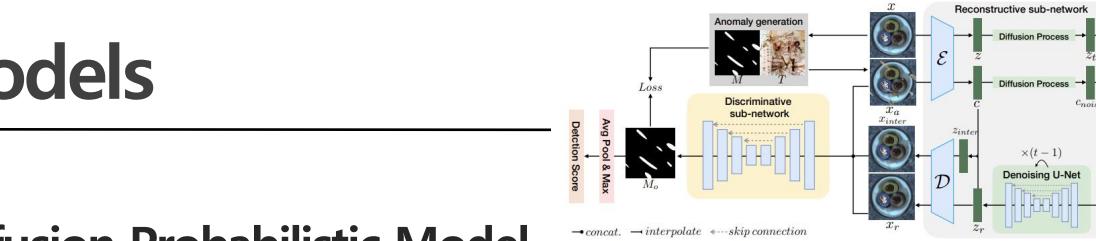
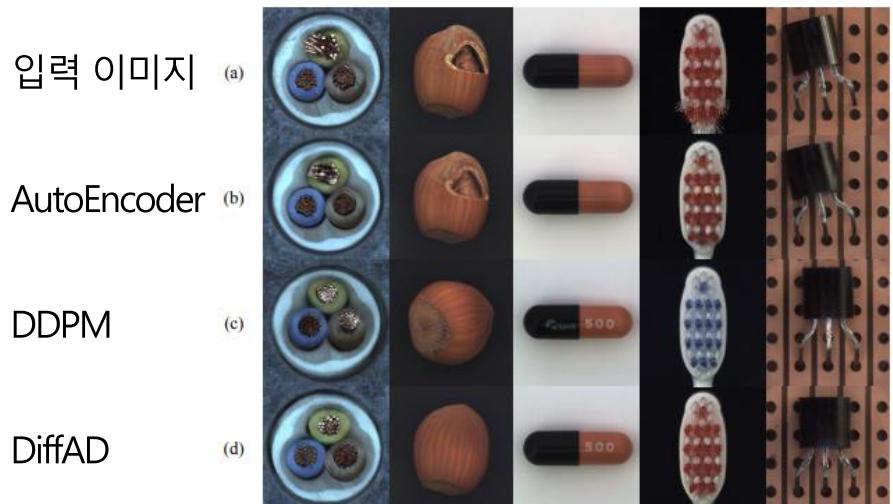
$x_r$



## 2. Diffusion-based Anomaly Detection models

### ❖ DiffAD: Unsupervised Surface Anomaly Detection with Diffusion Probabilistic Model

- Latent diffusion model을 이용하여 비지도 학습 Anomaly detection을 수행한 연구 (ICCV 2023)
  - 정상 영역과 이상치 영역의 구분을 유지하는 Noise 임베딩을 제안
  - 픽셀 수준 차이로 인해 발생하는 방해 요소를 개선하는 보간 채널 사용



	Class	[1]	[16]	[33]	[32]	Ours
texture	Carpet	82.1	<b>99.4</b>	84.2	97.0	98.3
	Grid	74.3	99.6	99.6	99.9	<b>100</b>
	Leather	80.8	97.1	<b>100</b>	<b>100</b>	<b>100</b>
	Tile	72.0	95.5	98.7	99.6	<b>100</b>
	Wood	92.0	95.7	93.0	99.1	<b>100</b>
object	Bottle	79.4	99.6	99.9	99.2	<b>100</b>
	Cable	71.1	<b>99.1</b>	81.9	91.8	94.6
	Capsule	72.1	96.2	88.4	<b>98.5</b>	97.5
	Hazelnut	87.4	98.5	83.3	<b>100</b>	<b>100</b>
	Metal Nut	69.4	<b>99.5</b>	88.5	98.7	<b>99.5</b>
	Pill	67.1	98.3	83.8	<b>98.9</b>	97.7
	Screw	<b>100</b>	<b>100</b>	84.5	93.9	97.2
	Toothbrush	70.0	98.7	<b>100</b>	<b>100</b>	<b>100</b>
	Transistor	80.8	<b>98.3</b>	90.9	93.1	96.1
	Zipper	74.4	99.0	98.1	<b>100</b>	<b>100</b>
Average		78.2	98.3	91.7	98.0	<b>98.7</b>

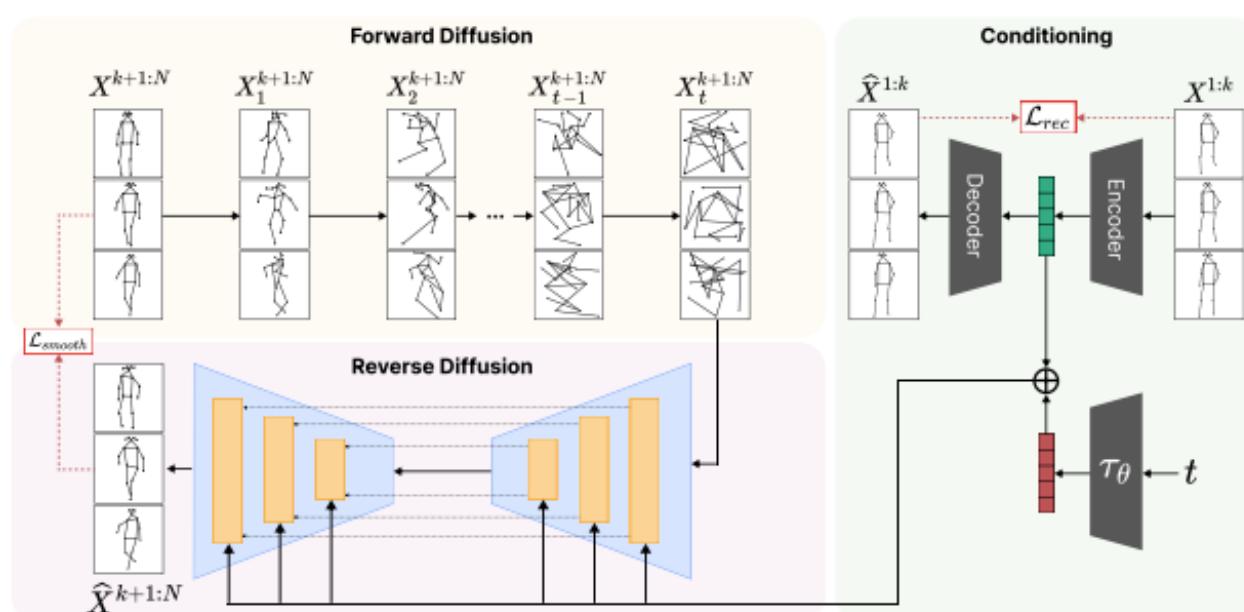
## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD: Multimodal Motion Conditioned Diffusion Model for Skeleton-based Video Anomaly Detection

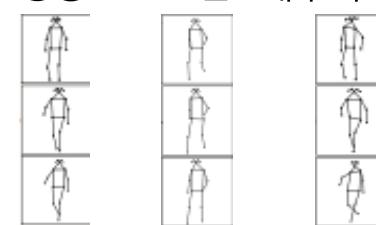
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)

- 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
- 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의

연구 목표

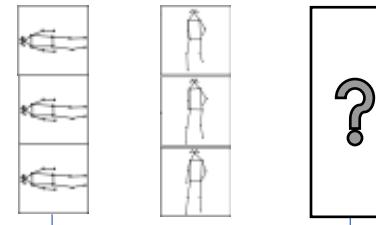


정상 조건 재구축 샘플



낮은 재구축 오차

이상치 조건 재구축 샘플

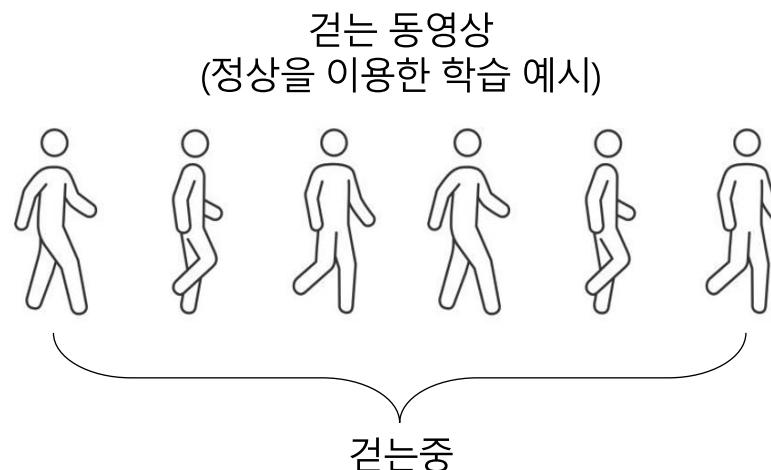


높은 재구축 오차

## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

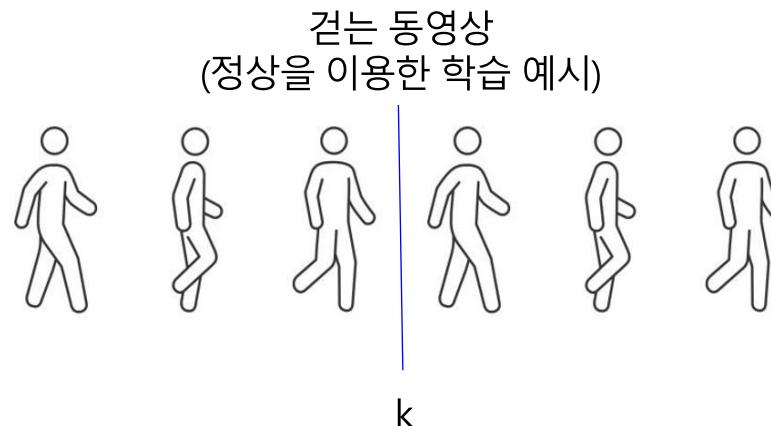
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

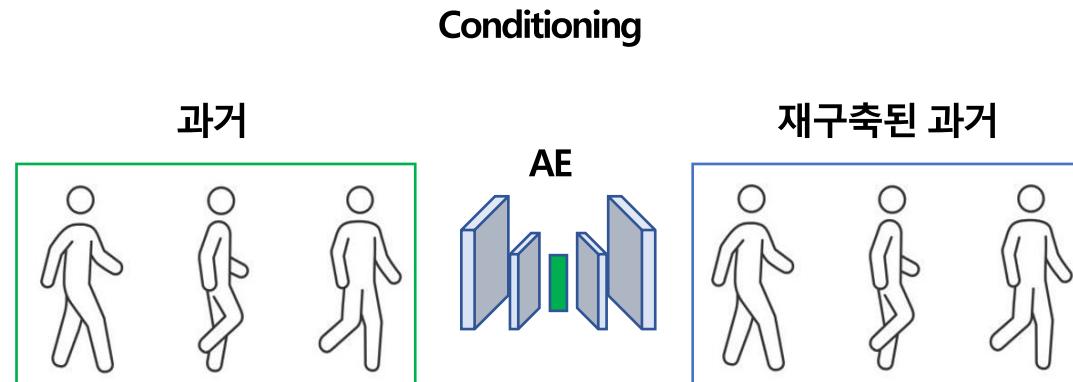
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

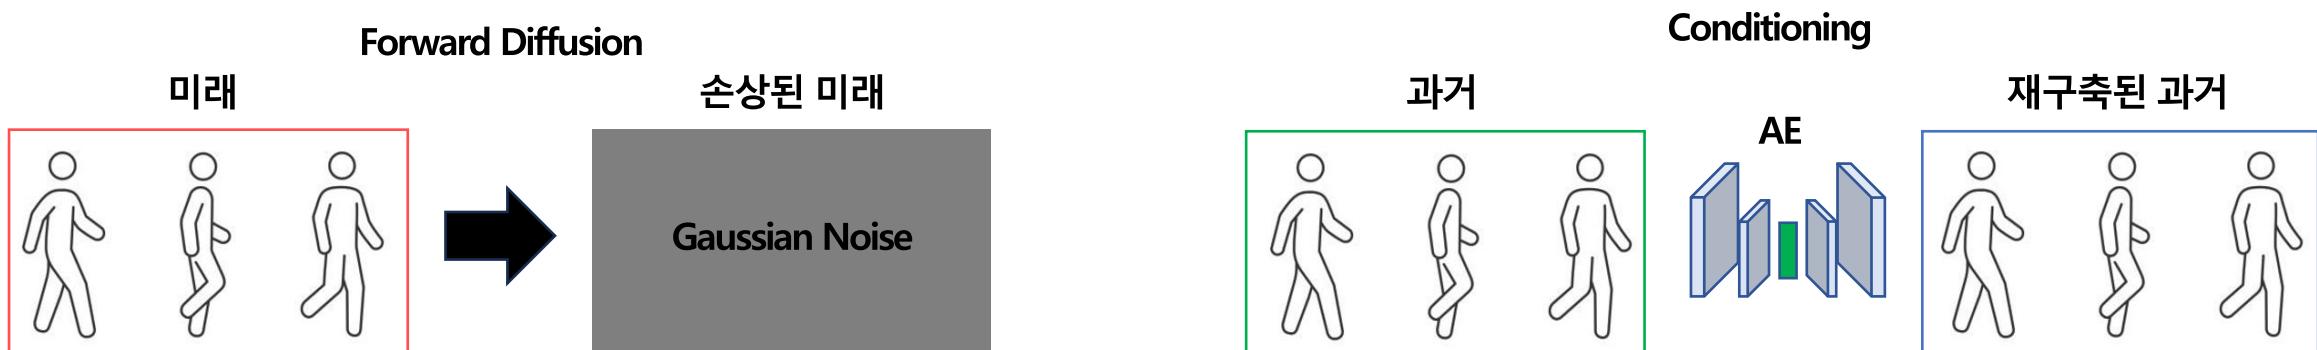
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

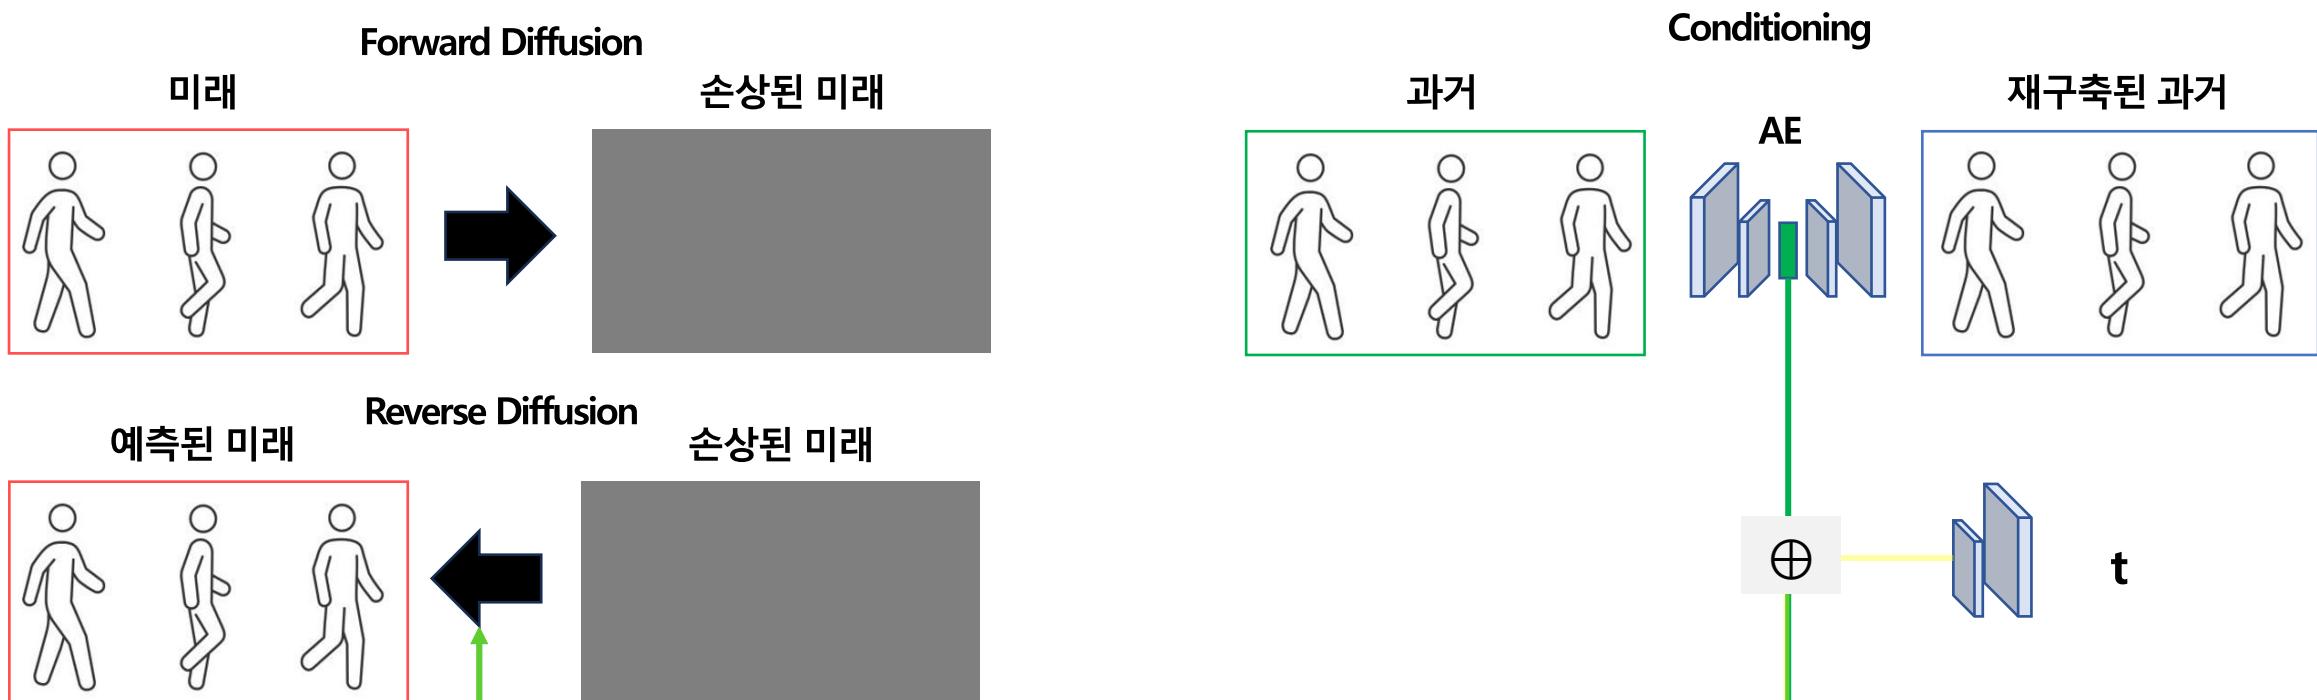
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

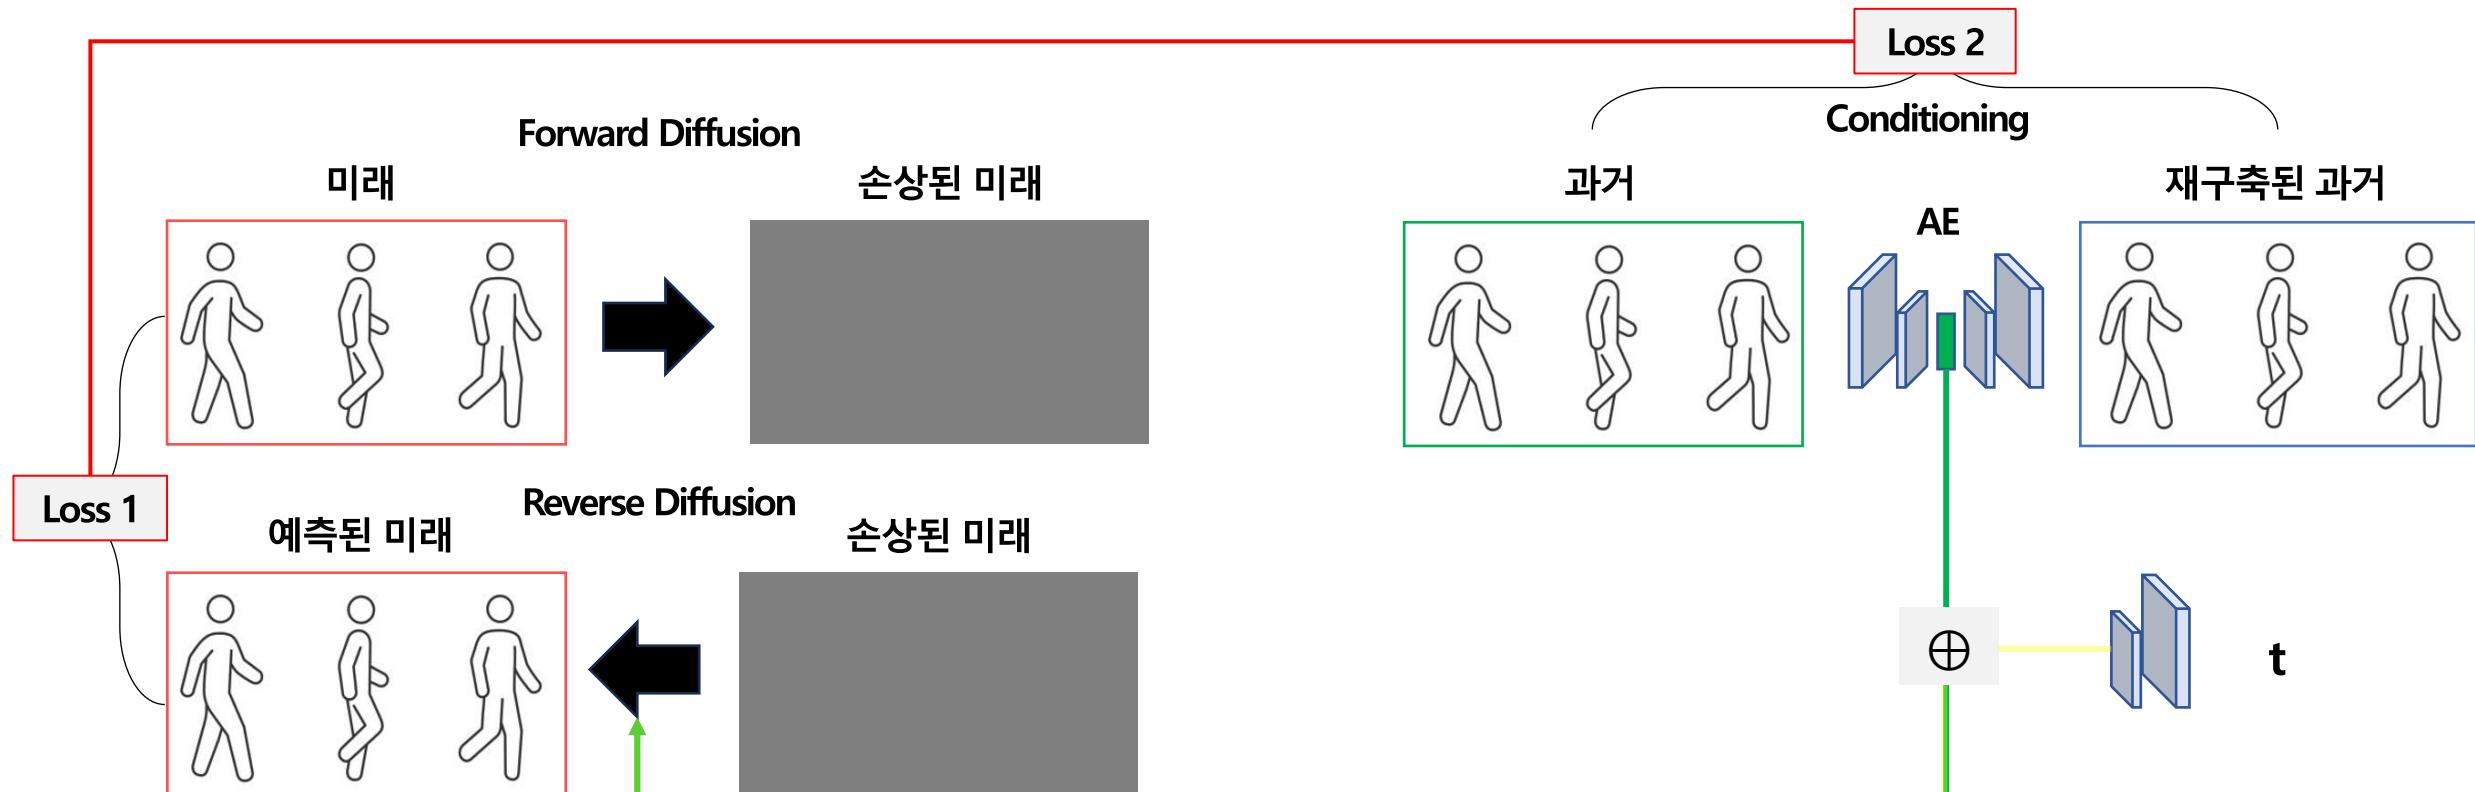
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 학습

- $k$ 를 기준으로 과거와 미래 데이터를 나눔 ( $1:k$ ,  $k:N$ )

- Conditioning

➤ 과거 데이터를 AE로 학습 (재구축 오차 산출)

$$\mathcal{L}_{rec} = \left\| D(E(X^{1:k})) - X^{1:k} \right\|_2^2$$

- Forward Diffusion

➤ 미래 데이터에 Gaussian Noise 처리

- Reverse Diffusion

➤ Noise 처리 된 미래 데이터에 과거 데이터 정보를 조건으로 주어 예측 행동을 생성

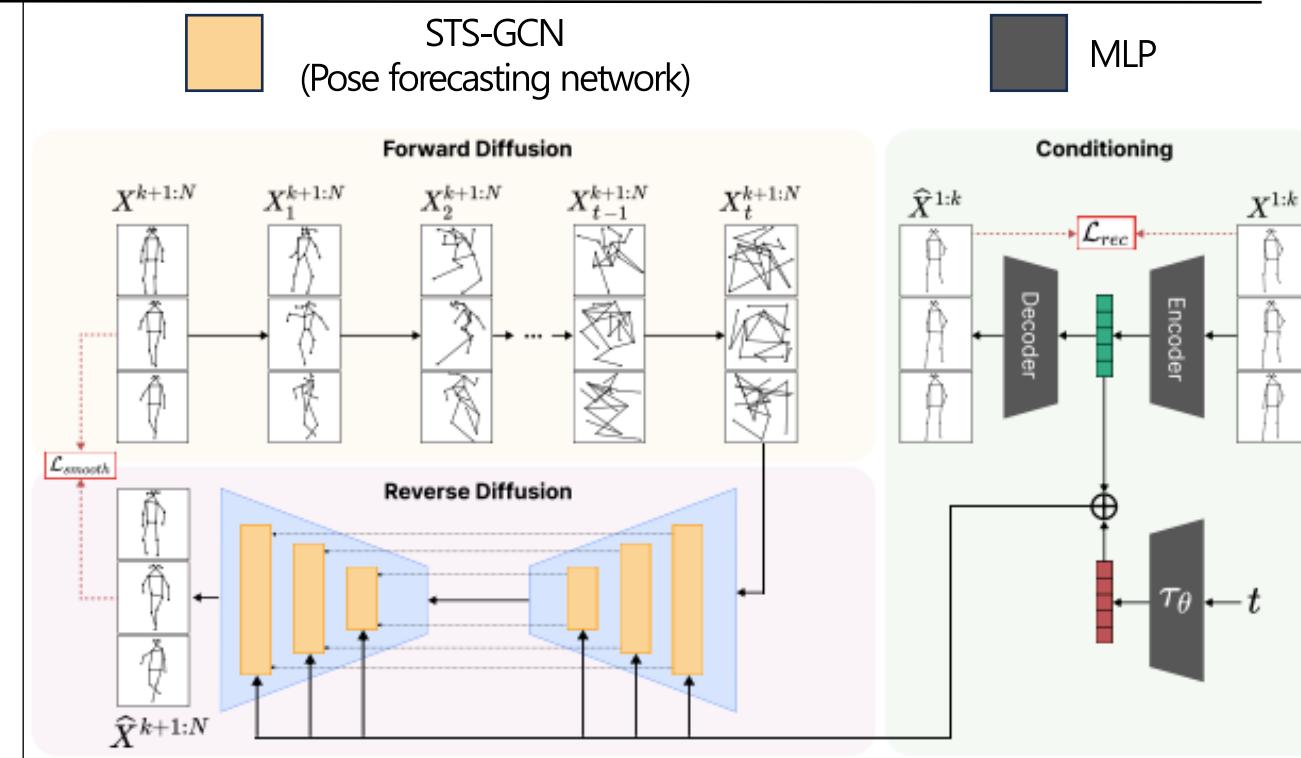
(미래 데이터와 예측 데이터 비교 오차 산출)

$$\mathcal{L}_{disp} = \mathbb{E}_{t, X, \varepsilon} \left[ \left\| \varepsilon - \varepsilon_{\theta}(X_t, t, h) \right\| \right]$$

$$\mathcal{L}_{smooth} = \begin{cases} 0.5 \cdot (\mathcal{L}_{disp})^2 & \text{if } |\mathcal{L}_{disp}| < 1 \\ |\mathcal{L}_{disp}| - 0.5 & \text{otherwise} \end{cases}$$

- 두 오차를 lambda 비율로 합하여 학습 수행 (논문에서는 1:1)

$$\mathcal{L}_{tot} = \lambda_1 \mathcal{L}_{smooth} + \lambda_2 \mathcal{L}_{rec}$$



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

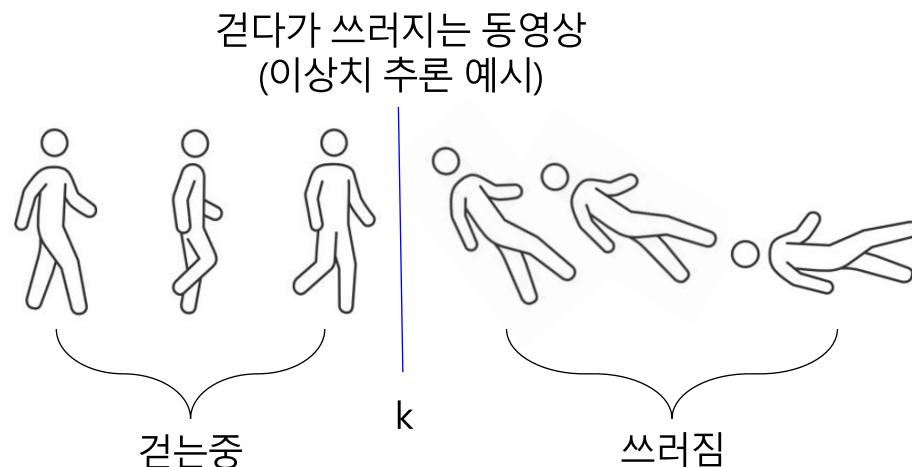
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

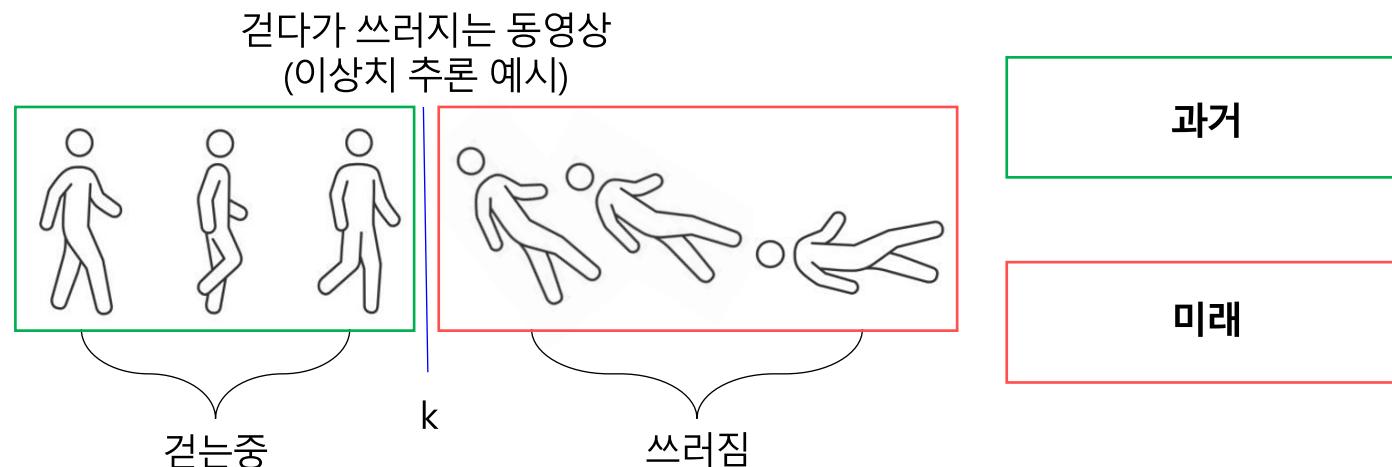
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

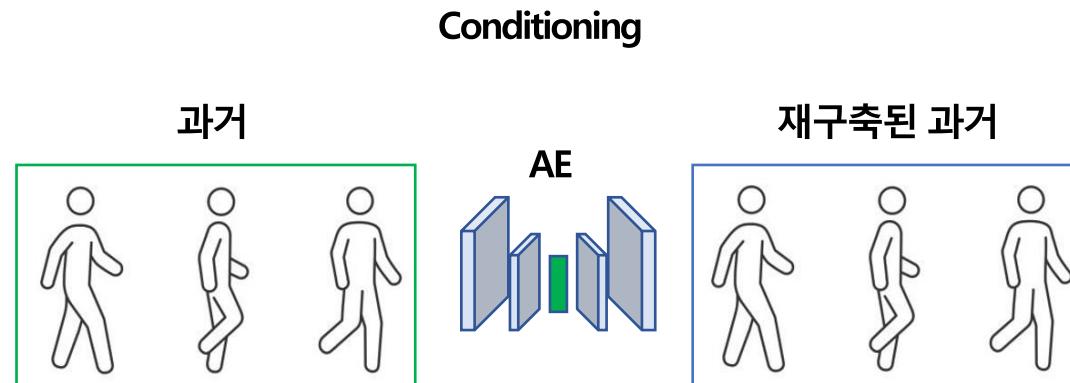
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

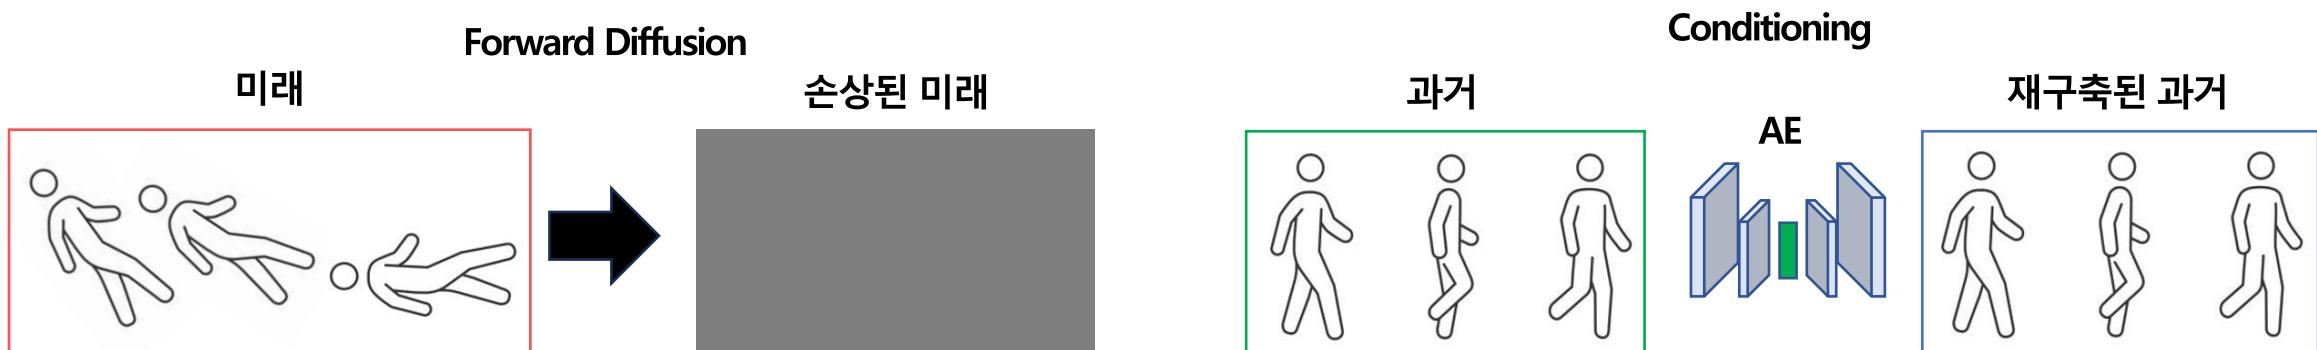
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

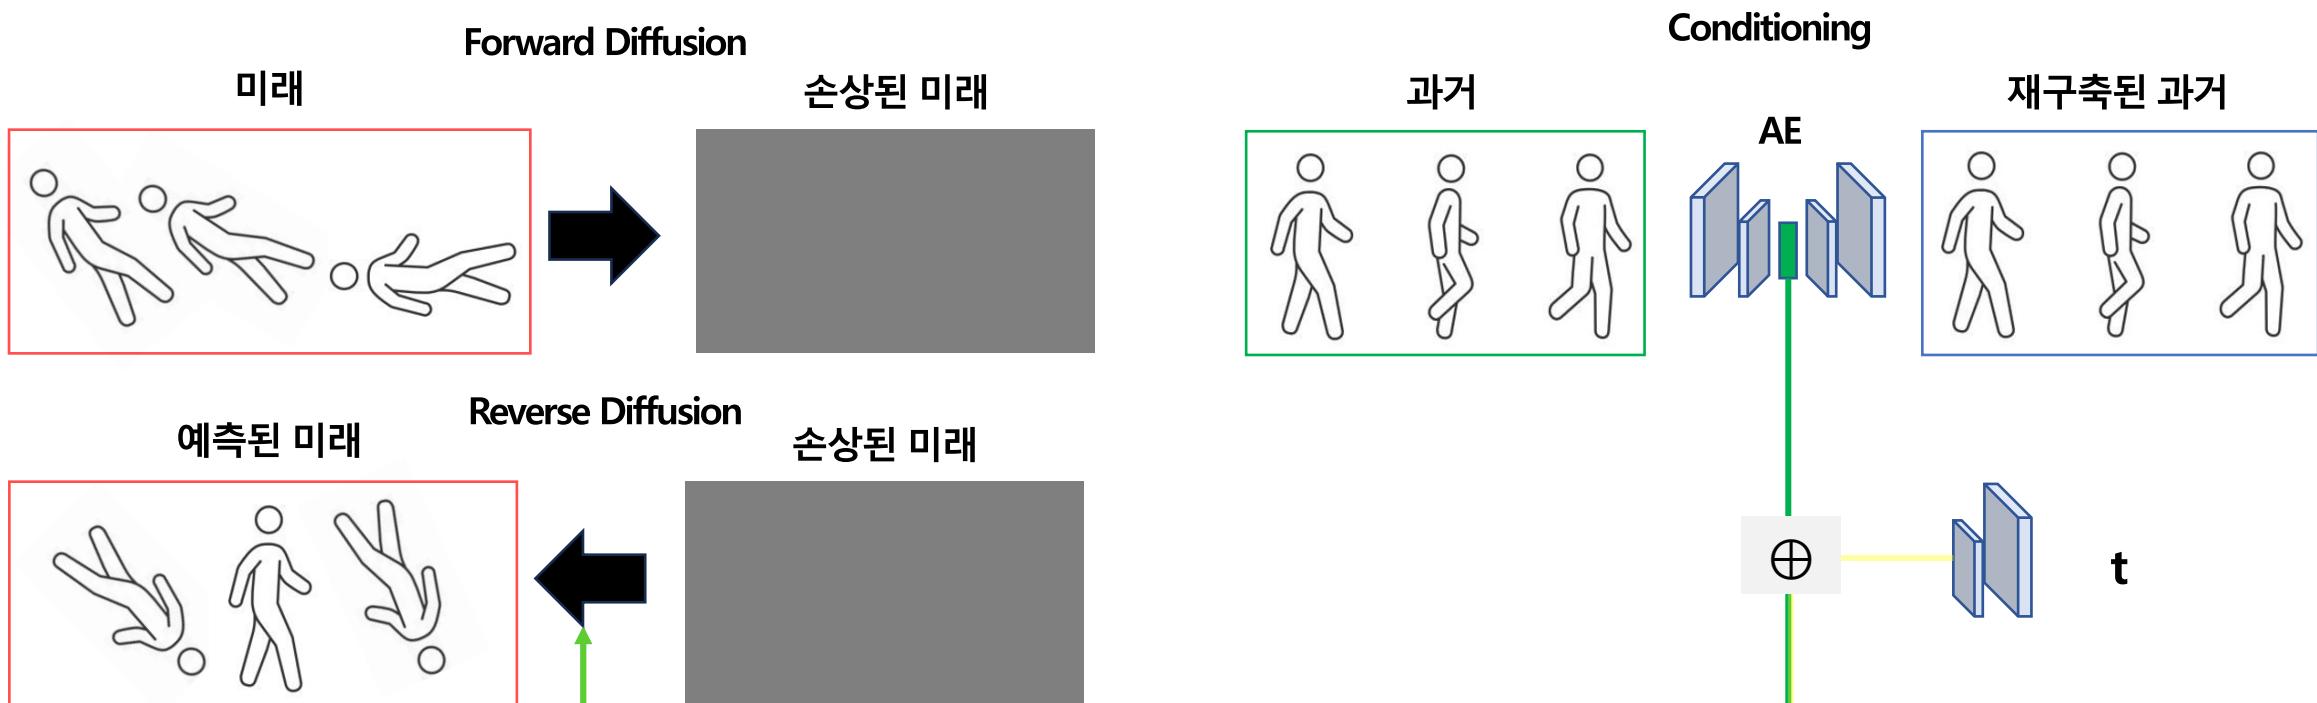
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

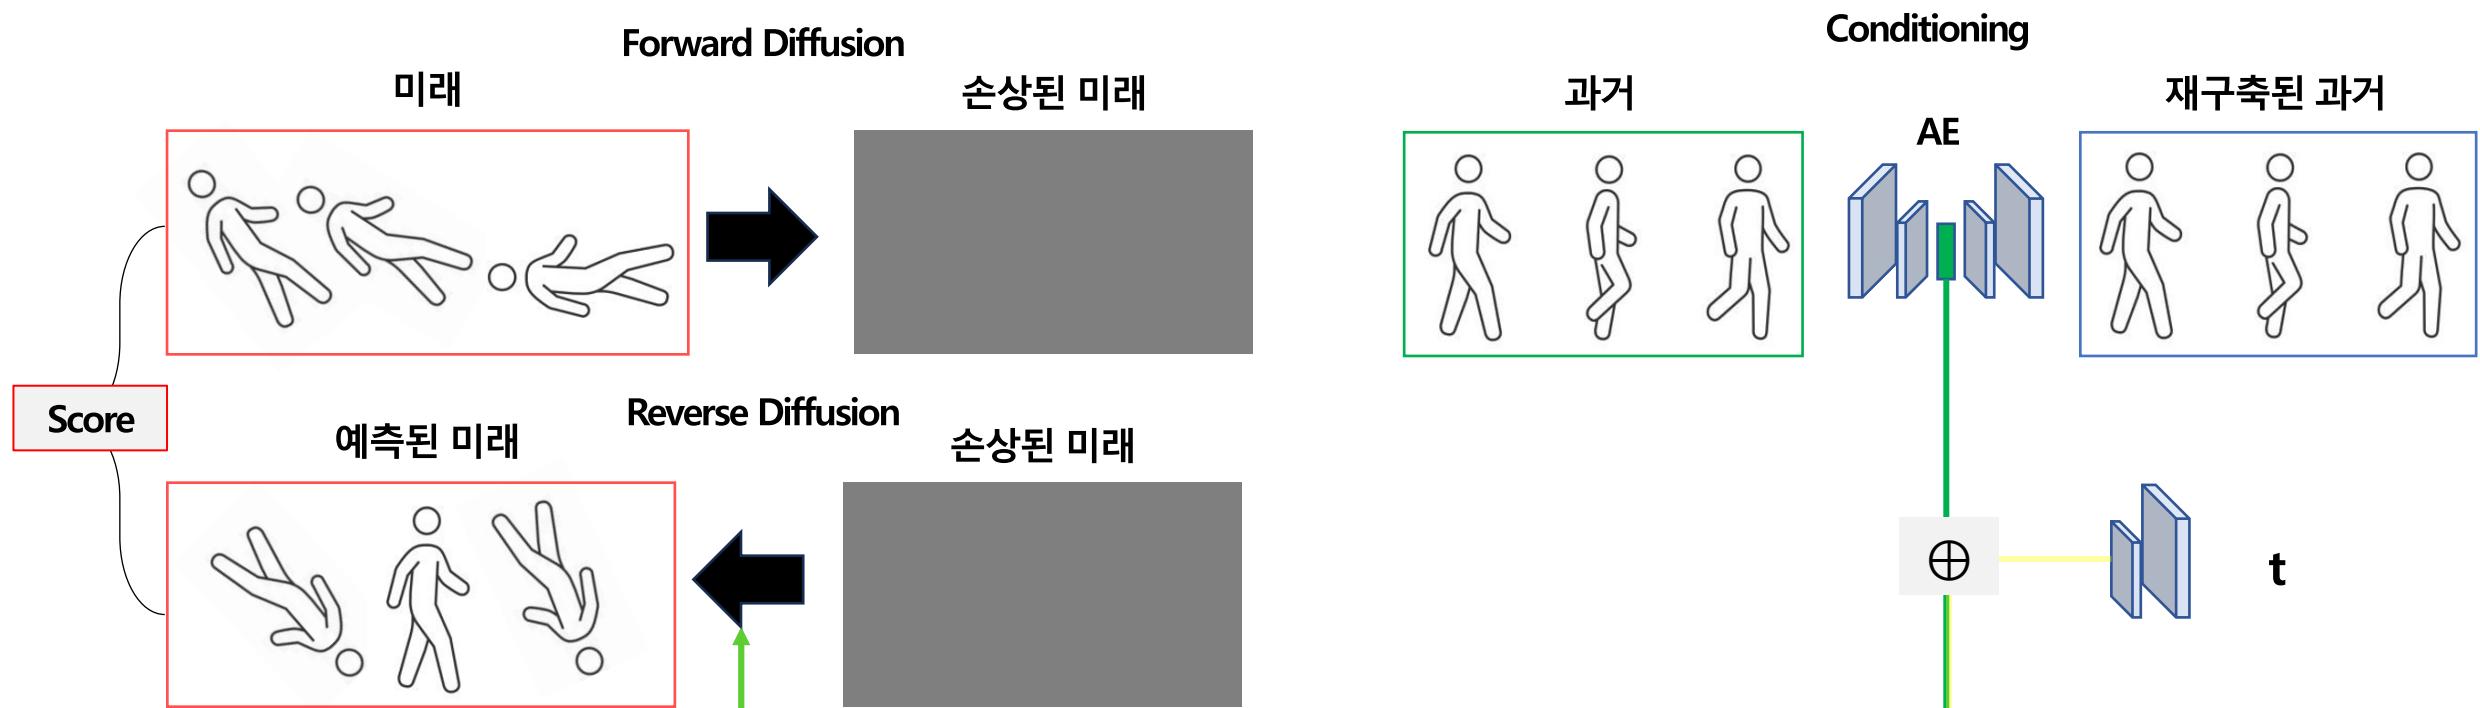
- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

- HR-VAD 분야에서 최초로 Diffusion을 적용한 모델 (ICCV 2023)
  - 과거 행동을 Condition으로 사용하여 그럴듯한 미래 동작을 생성
  - 미래 패턴을 통계적으로 집계하여 생성된 일련의 동작이 실제 미래 추세에서 벗어날 때를 이상치로 정의



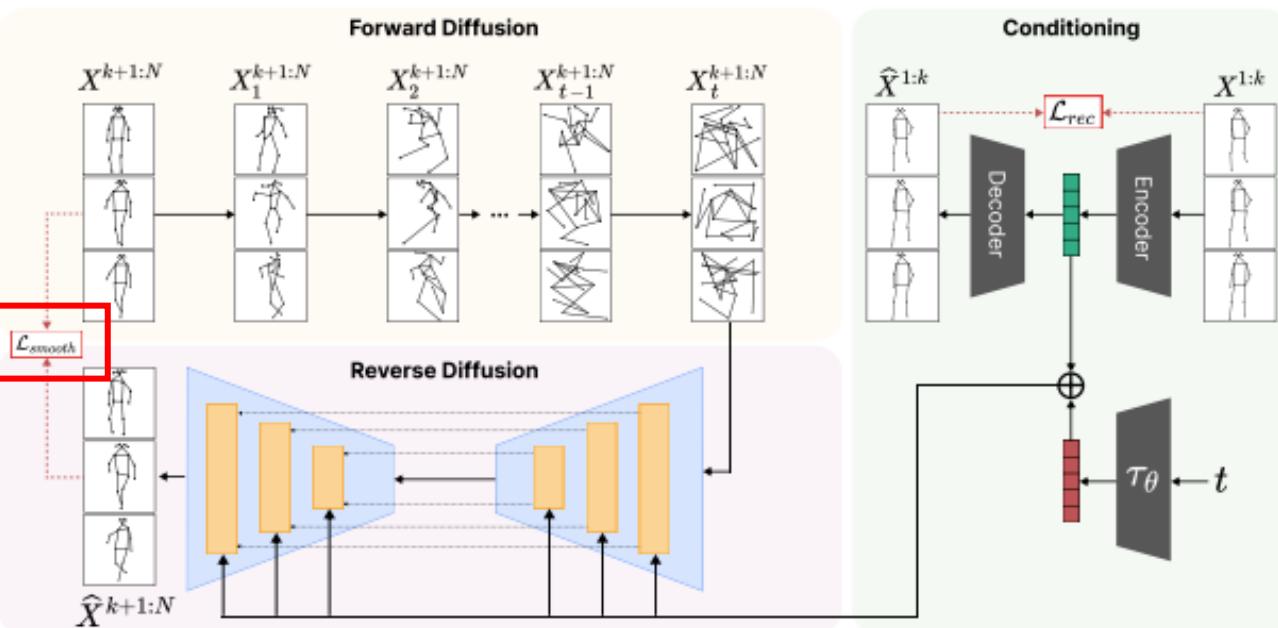
## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 추론

- Anomaly Detection 방법
  - 학습 구조는 그대로 활용하고 미래 데이터와 예측 데이터 비교 오차를 score로 사용하여 Anomaly score 계산
  - AUC-ROC를 통해 모델을 평가 진행

$$\text{SCORE}_j = \mathcal{L}_{smooth}(\hat{\mathcal{F}}_j, \mathcal{F})$$

$$\text{AS}[f_1 : f_N] = \text{mean}(\mathcal{S}) + \log \frac{1 + \max(\mathcal{S})}{1 + \min(\mathcal{S})}.$$



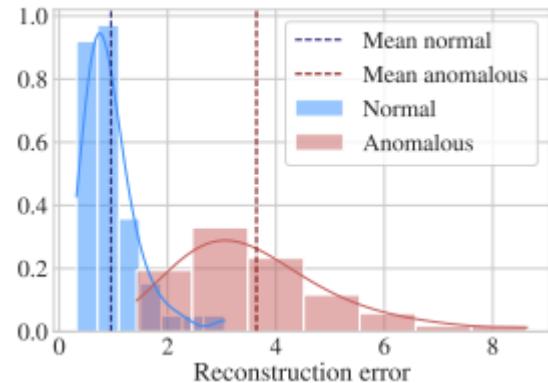
## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 결과

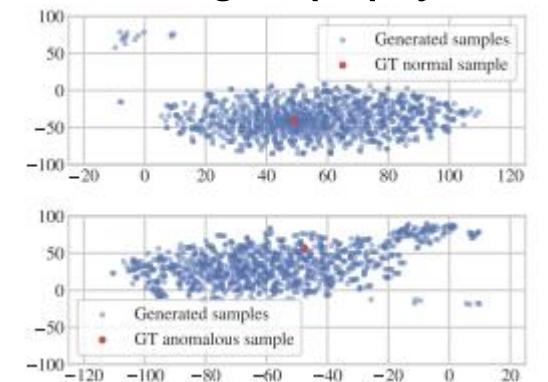
- HR-VAD 분야 알고리즘 SOTA 달성
- 과거 데이터를 이용한 Conditioning 재구축 모델 또한 정상과 비정상의 차이가 확실함
- t-SNE를 이용하여 샘플링 했을 때, 정상과 비정상 모두 비슷한 군집을 이룬 것을 확인

		HR-STC	HR-Avenue	HR-UBnormal		UBnormal
Conv-AE [13]	CVPR '16	69.8	84.8	-		-
Pred [21]	CVPR '18	72.7	86.2	-		-
MPED-RNN [26] *	CVPR '19	75.4	86.3	61.2		60.6
GEPC [25] *	CVPR '20	74.8	58.1	55.2		53.4
Multi-timescale Prediction [32] *	WACV '20	77.0	88.3	-		-
Normal Graph [24]	Neurocomputing '21	76.5	87.3	-		-
PoseCVAE [15] *	ICPR '21	75.7	87.8	-		-
BiPOCO [17] *	Arxiv '22	74.9	87.0	52.3		50.7
STGCAE-LSTM [20] *	Neurocomputing '22	77.2	86.3	-		-
SSMTL++ [3]	CVIU '23	-	-	-		62.1
COSKAD [9] *	Arxiv '23	77.1	87.8	65.5		65.0
MoCoDAD *		<b>77.6</b>	<b>89.0</b>	<b>68.4</b>		<b>68.3</b>

Conditioning 재구축 오차



Conditioning sample projection



## 2. Diffusion-based Anomaly Detection models

### ❖ MoCoDAD 결과

- Supplements에 포함된 기타 실험
  1. Diffusive steps 횟수에 따라 성능을 비교
  2. Noise와 MoCo(과거 시점 condition) 적용에 따른 성능을 비교
  3. Noise 별 시각화

Diffusive steps에 따른 성능 비교	
Diffusive steps	HR-UBnormal    UBnormal
2	65.0    64.7
5	66.3    65.9
10	<b>68.4</b>    <b>68.3</b>
25	64.70    64.6
50	64.4    64.4

Noise와 MoCo 적용에 따른 성능 비교				
$\gamma/T$	Corruption	MoCo	HR-UBnormal	UBnormal
3/10	Simplex	✗	53.0	52.0
3/10	Gaussian	✗	57.4	57.3
10/10	Gaussian	✗	55.0	54.1
10/10	Gaussian	✓	<b>68.4</b>	<b>68.3</b>

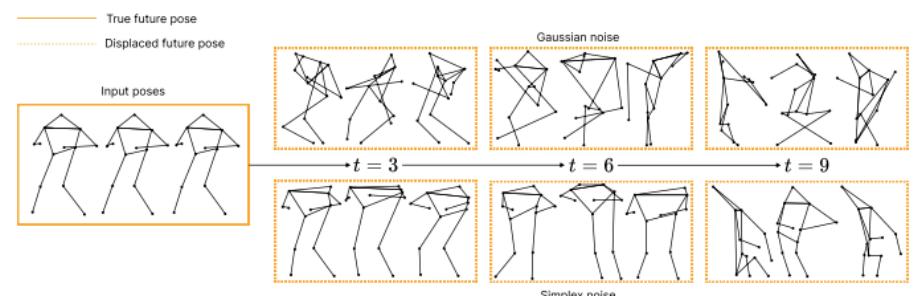
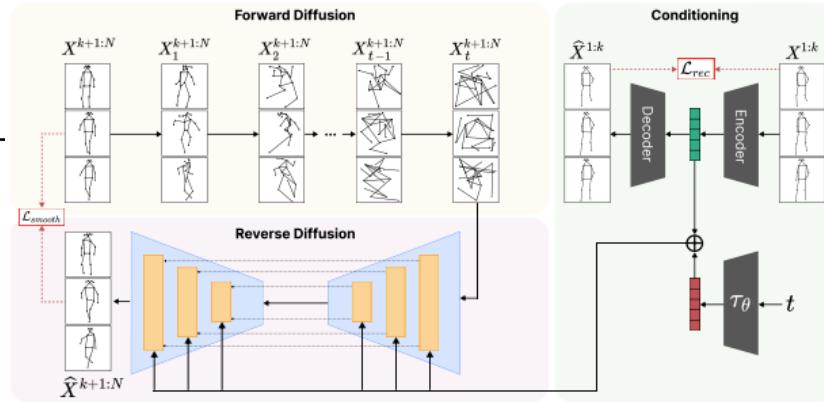


Figure 2: Comparison of Gaussian (up) vs Simplex (down) noises applied to a sequence of future poses.



# 3. Conclusion

---

## ❖ Anomaly Detection

- 이상치는 대부분의 데이터와 본질적인 특성이 다른 관측치를 의미
- 현실에서 이상치 샘플이 적은 경우에 분류 모델보다 적합

## ❖ Diffusion models

- Forward Diffusion Process 를 통해 샘플에 노이즈를 주고 Reverse Process를 통해 샘플을 복구하는 과정
- GAN과 VAE의 단점을 보완한 높은 퀄리티와 다양한 샘플을 가질 수 있는 Diffusion models (샘플 생성 속도가 느림)

## ❖ Diffusion-based Anomaly Detection models

- 뇌에 악성 종양이 있는지 판단하는 AnoDDPM (partial diffusion strategy)
- 품질 검사 라인에서 이상치 탐지를 수행하는 DiffAD (latent encoding)
- 동영상으로부터 사람의 이상 행동을 탐지하는 MoCoDAD (skeleton data)

# 고맙습니다