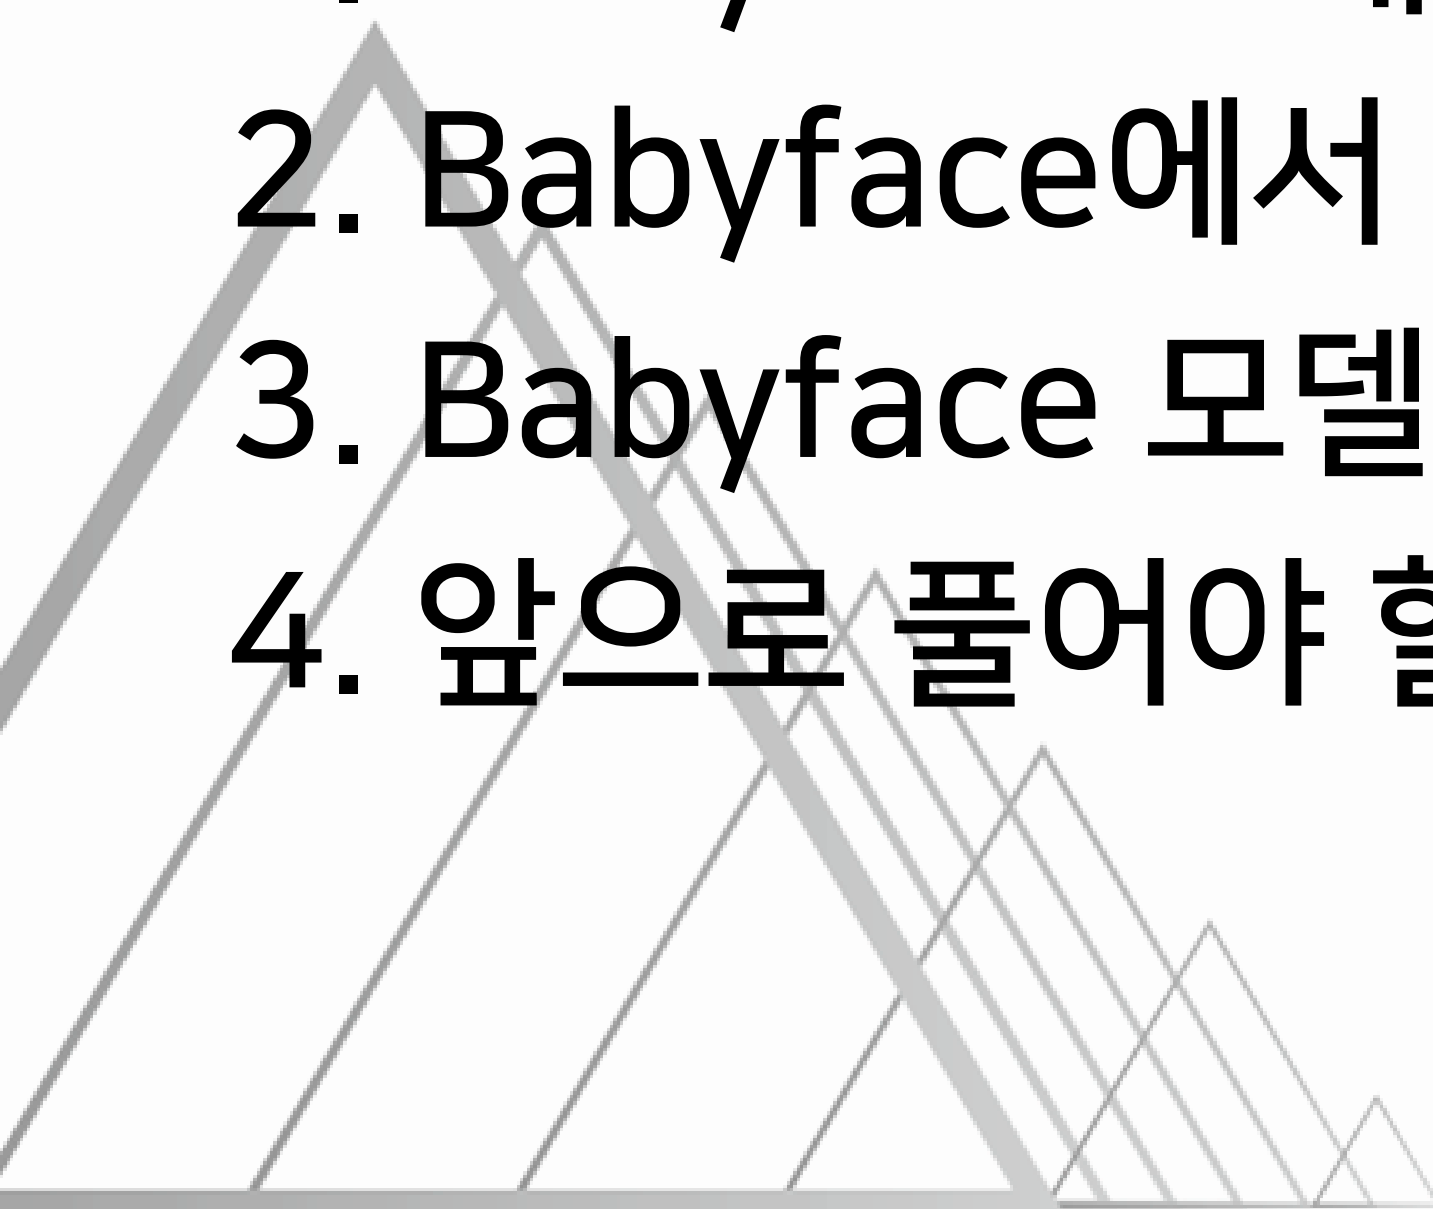


인공지능으로 아기 얼굴 미리보기

: 노이즈가 심한 환경에서 이미지 변환 적용하기 (Babyface1.0)

CONTENTS

1. Babyface 소개
2. Babyface에서 해결해야하는 문제
3. Babyface 모델 1.0 : GET-GAN
4. 앞으로 풀어야 할 문제들




1. Babyface 소개

1.1 Babyface 서비스 소개

임신 25주차에 촬영하는 입체 초음파,
심한 가려짐과 왜곡 때문에 산모들의 궁금증을 해결하기에 부족함


입체 초음파 얼굴이
가려지고 흐릿해서
잘 보이지 않아..



1.1 Babyface 서비스 소개

Babyface는 인공지능 이미지 변환기술을 이용하여
입체 초음파 이미지로부터 생후 아기 모습을 예측하는 서비스

어멋!
아기 얼굴이 이렇게
생생하게 보이다니!!



초음파 예측 얼굴 초음파 예측 얼굴



1.2 Babyface에서 사용하는 기술



Deep Generative Models

우리가 알고 있는 분포로부터
원하는 타겟 도메인의 분포를 추정하는 모델


여러가지 생성 모델들...

- Generative Adversarial Networks (GANs)
- Variational Autoencoder
- Generative FLOW
- Denoising Diffusion Prob. Model

알고 있는
분포



Generative
Model





알고 싶은
분포




1.3 Babyface에서 사용하는 기술

GANs 기반의 이미지 변환 기술
(I2I : Image-to-Image Translation)

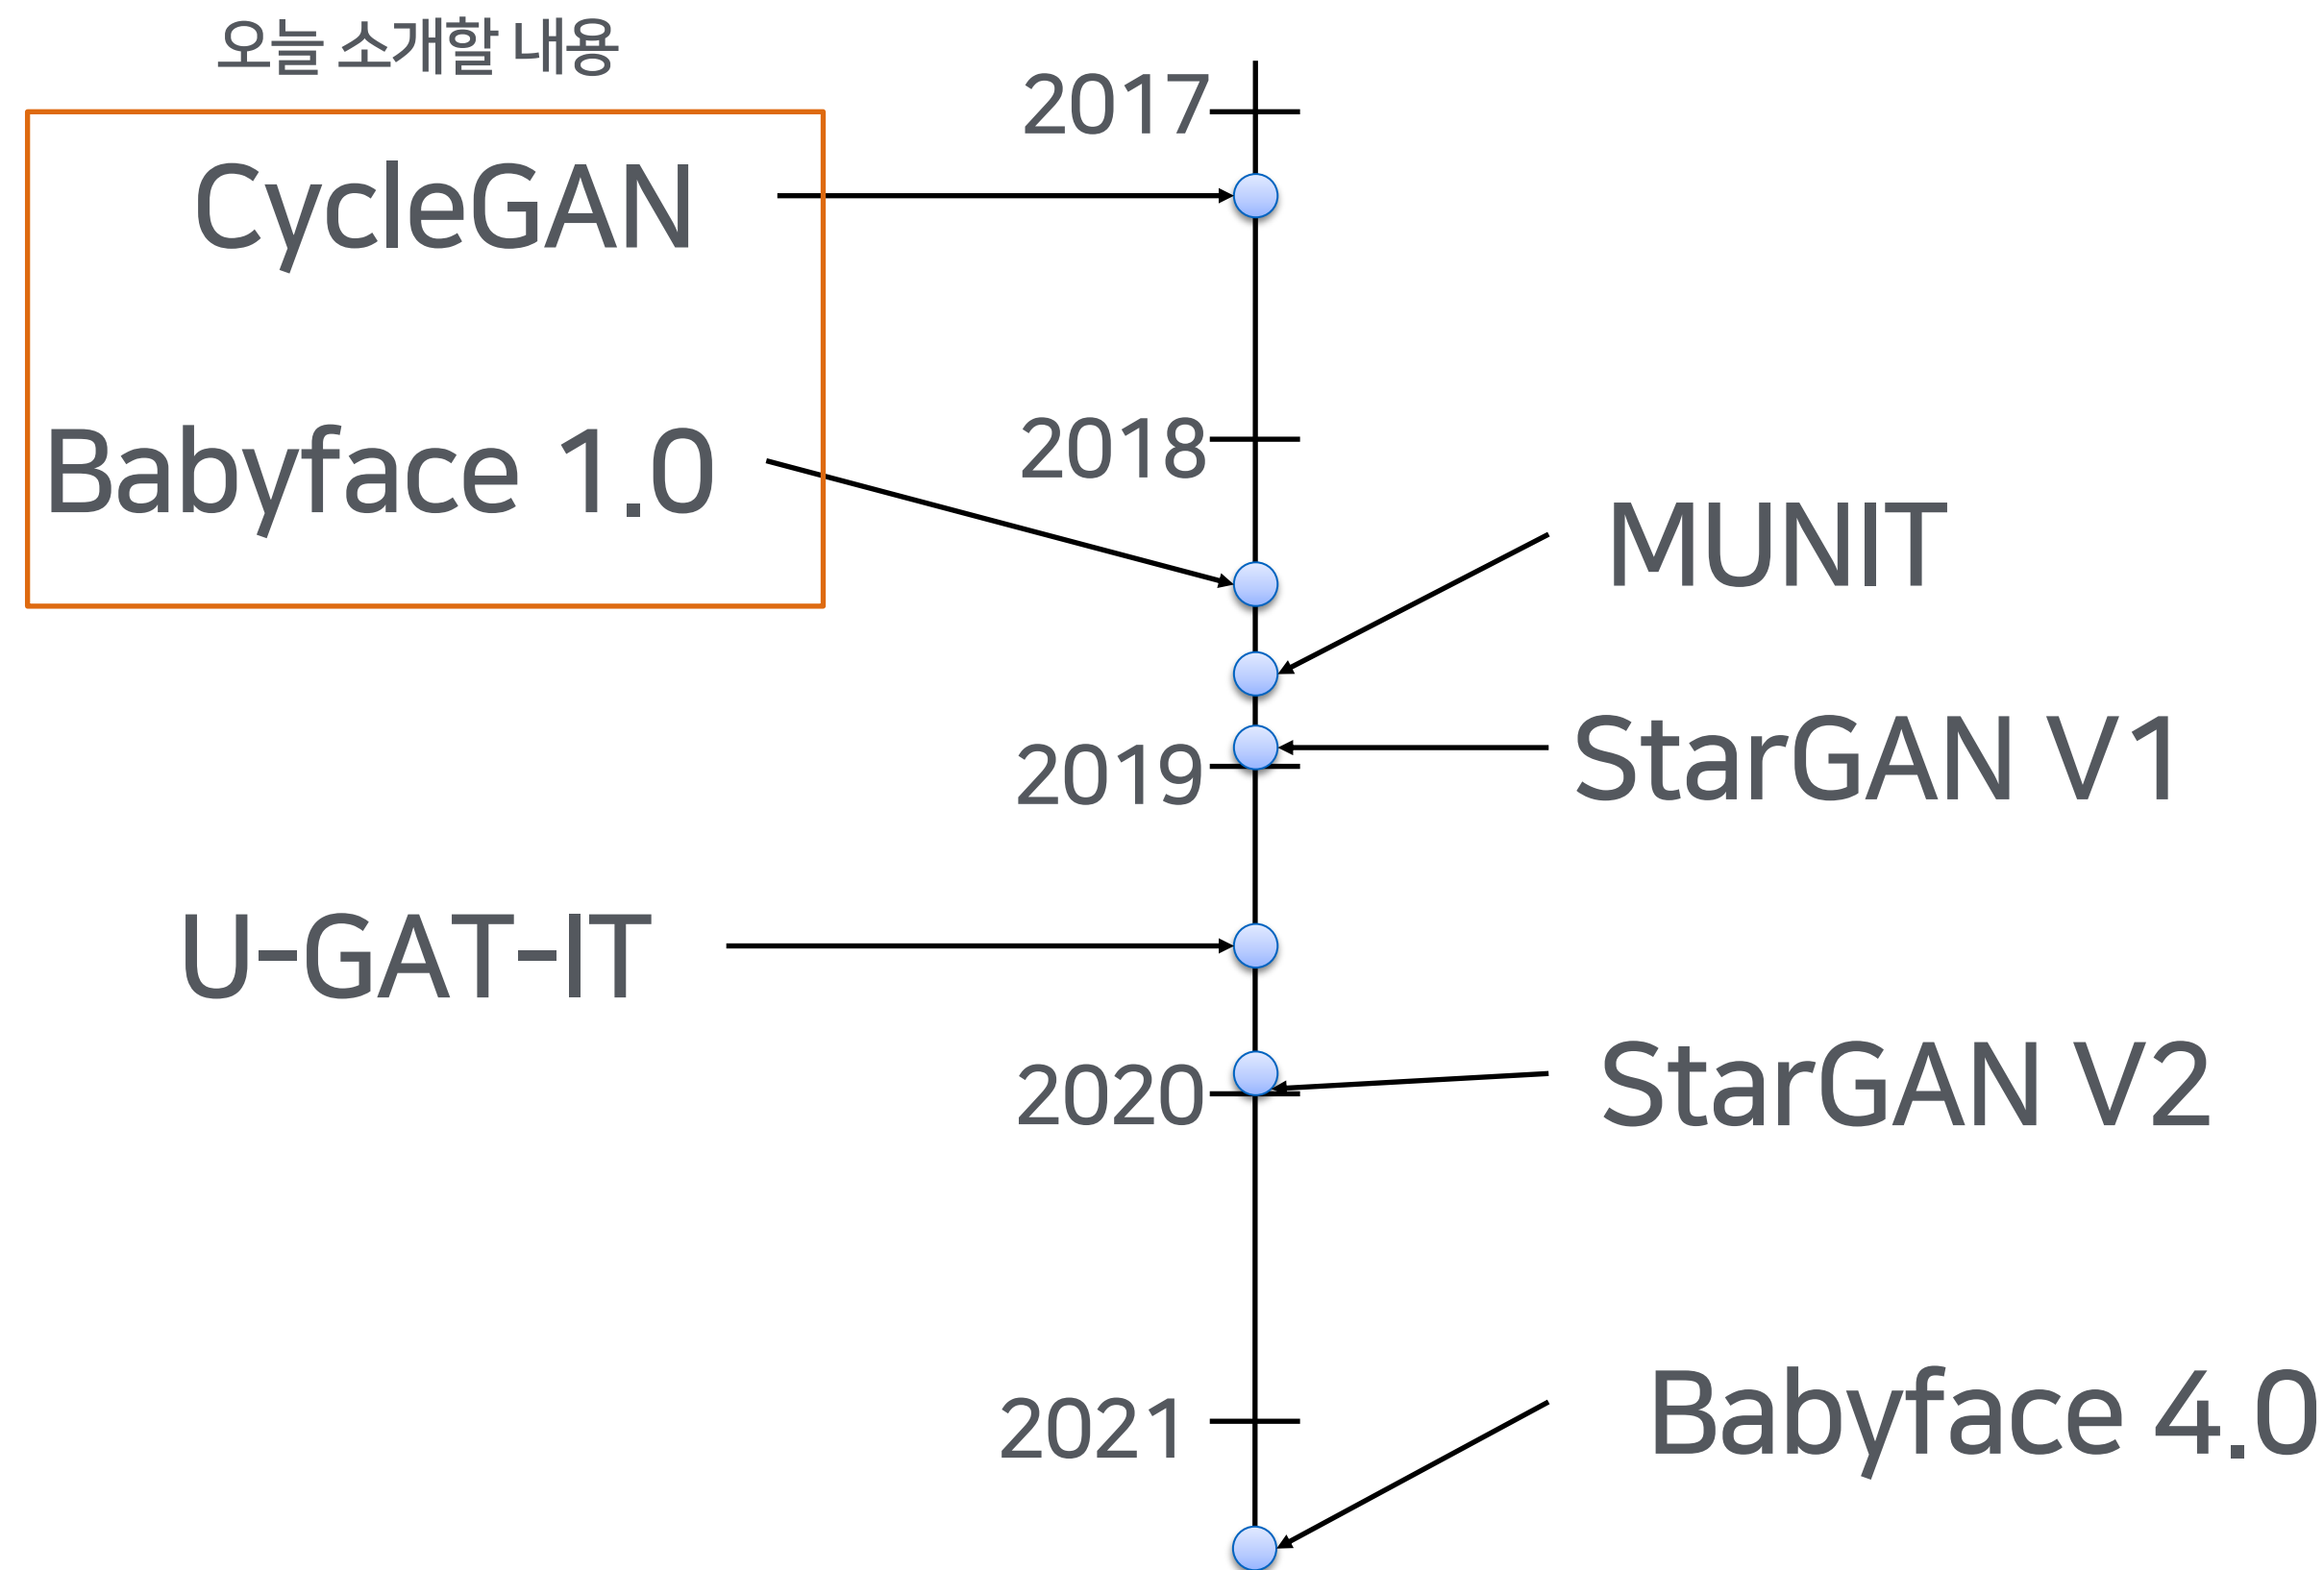
소스 도메인
이미지



타겟 도메인
이미지



*이미지 출처 : U-GAT-IT, Junho Kim et. al




1.4 Babyface에서 사용하는 기술

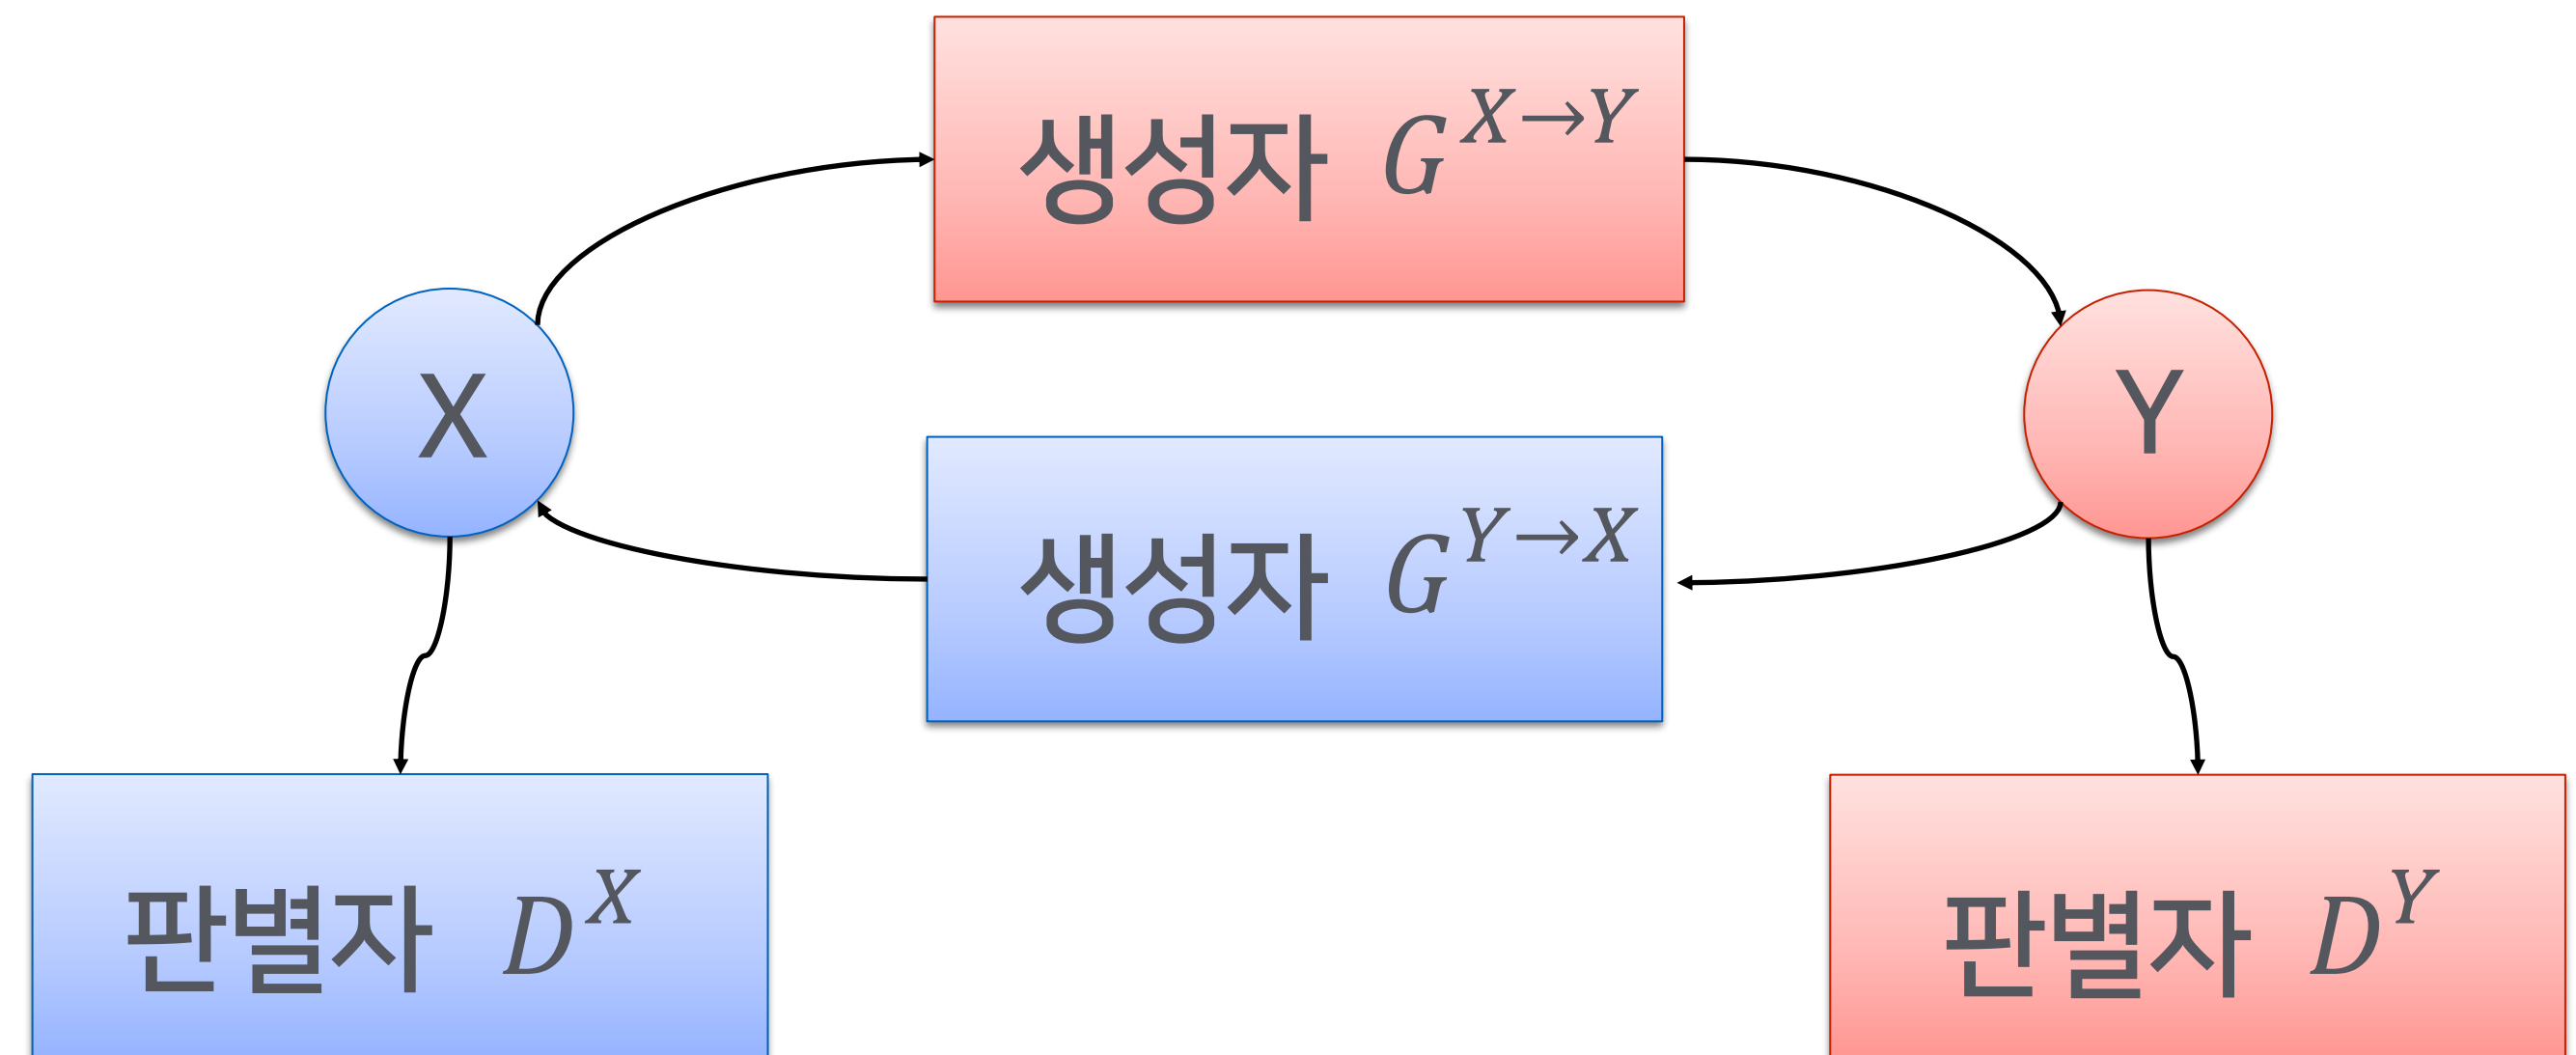
Babyface 1.0 모델은 CycleGAN을 바탕으로 함

Key idea : 소스 도메인의 이미지를 타겟 도메인으로 변환한 후,
다시 소스 도메인으로 변환하면 원래 이미지와 같지 않을까?

Cycle Consistency



CycleGAN의 구조



2. Babyface 변환 모델이 해결해야할 문제

2.1 Babyface에서 해결해야 할 문제

가려짐과 왜곡이 심한 입체 초음파

대부분이 손과 발, 태반 등의 장애물로 가려지거나 복합적인 왜곡이 발생



태반이나 자궁벽



손이나 발




기타 왜곡

2.2 기존 기술의 문제점

Cycle consistency loss

- 원본 이미지와, 변환 후 복원한 이미지가 같아지도록 학습
- Solution space를 제약함으로써 학습을 안정화하고, mode collapsing을 방지함
- 그러나 입체 초음파 이미지에는 적합하지 않음




2.2 기존 기술의 문제점

Cycle consistency를 만족하려면 변환된 이미지가
원본 이미지의 모든 특징을 포함해야 함

가려지거나 왜곡이 있는 부분의 흔적이 변환된 이미지에 그대로 남게 됨

X (입체 초음파)

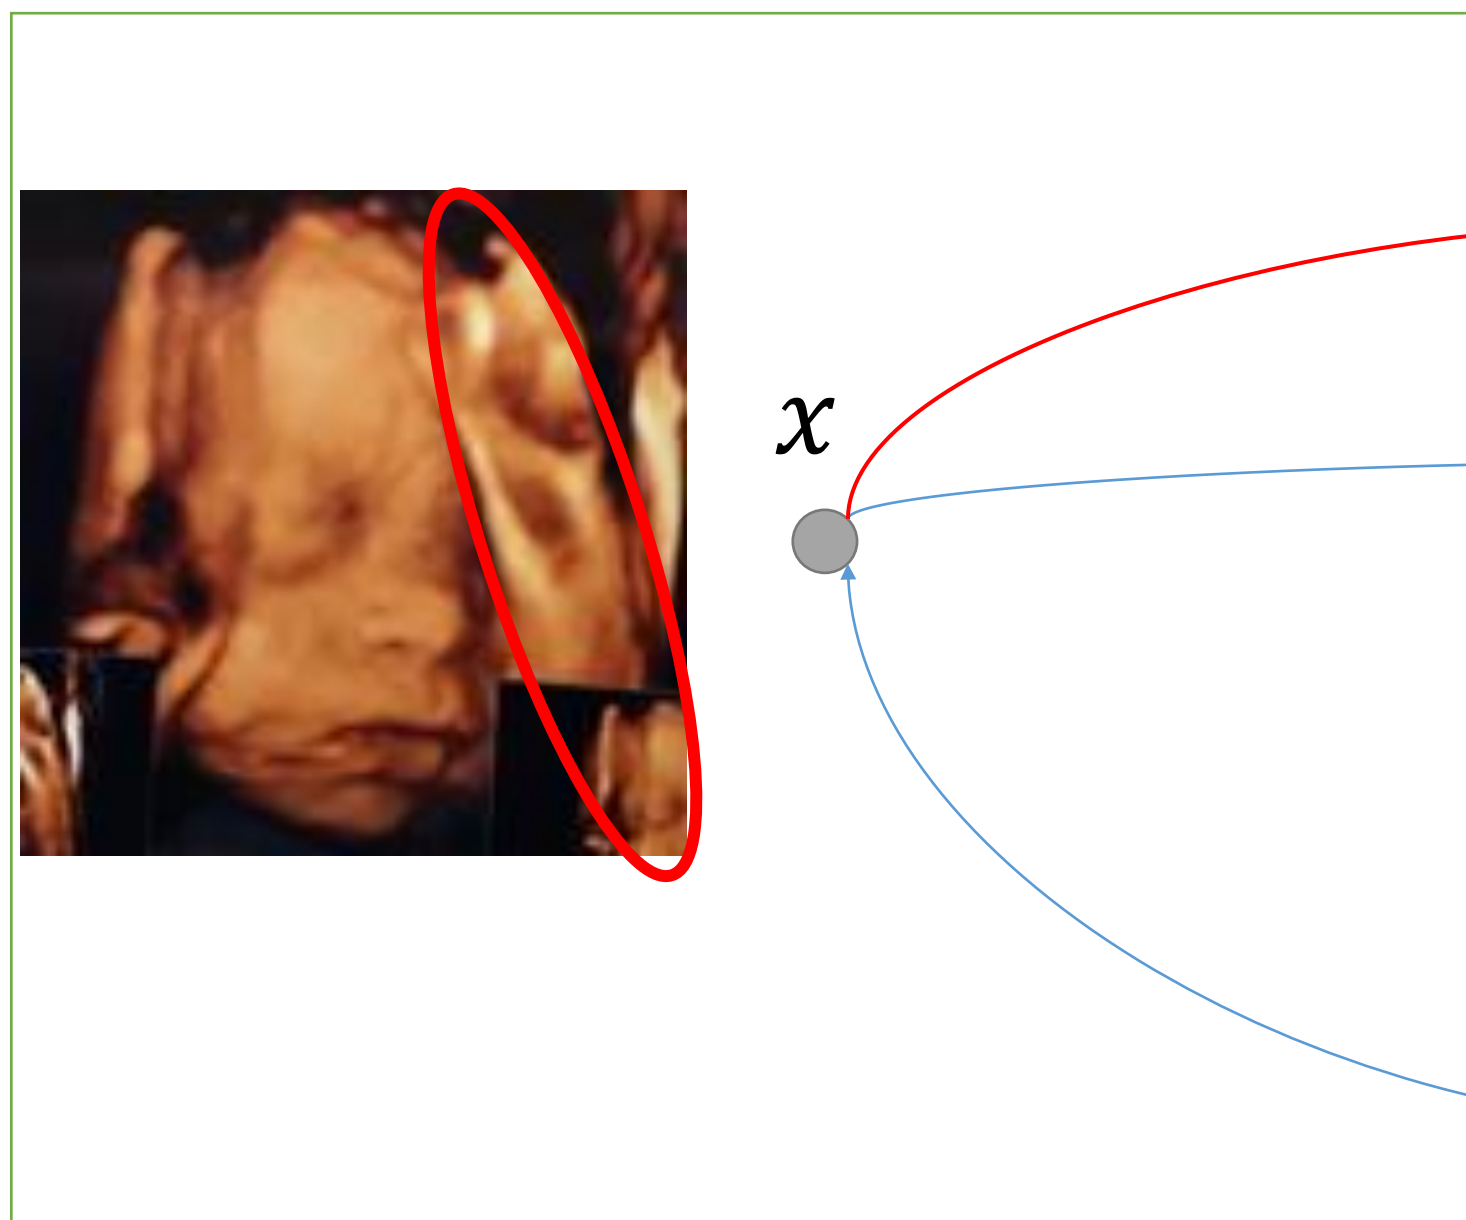
Y (아기 실사)



2.2 기존 기술의 문제점

Cycle consistency의 장점을 활용함과 동시에
노이즈가 심한 이미지도 변환이 되게 하려면?

X (입체 초음파)



Y (아기 실사)



what we want

y_*

what we got

y

x

3. Babyface 모델 1.0 : GET-GAN

3.1 Error term

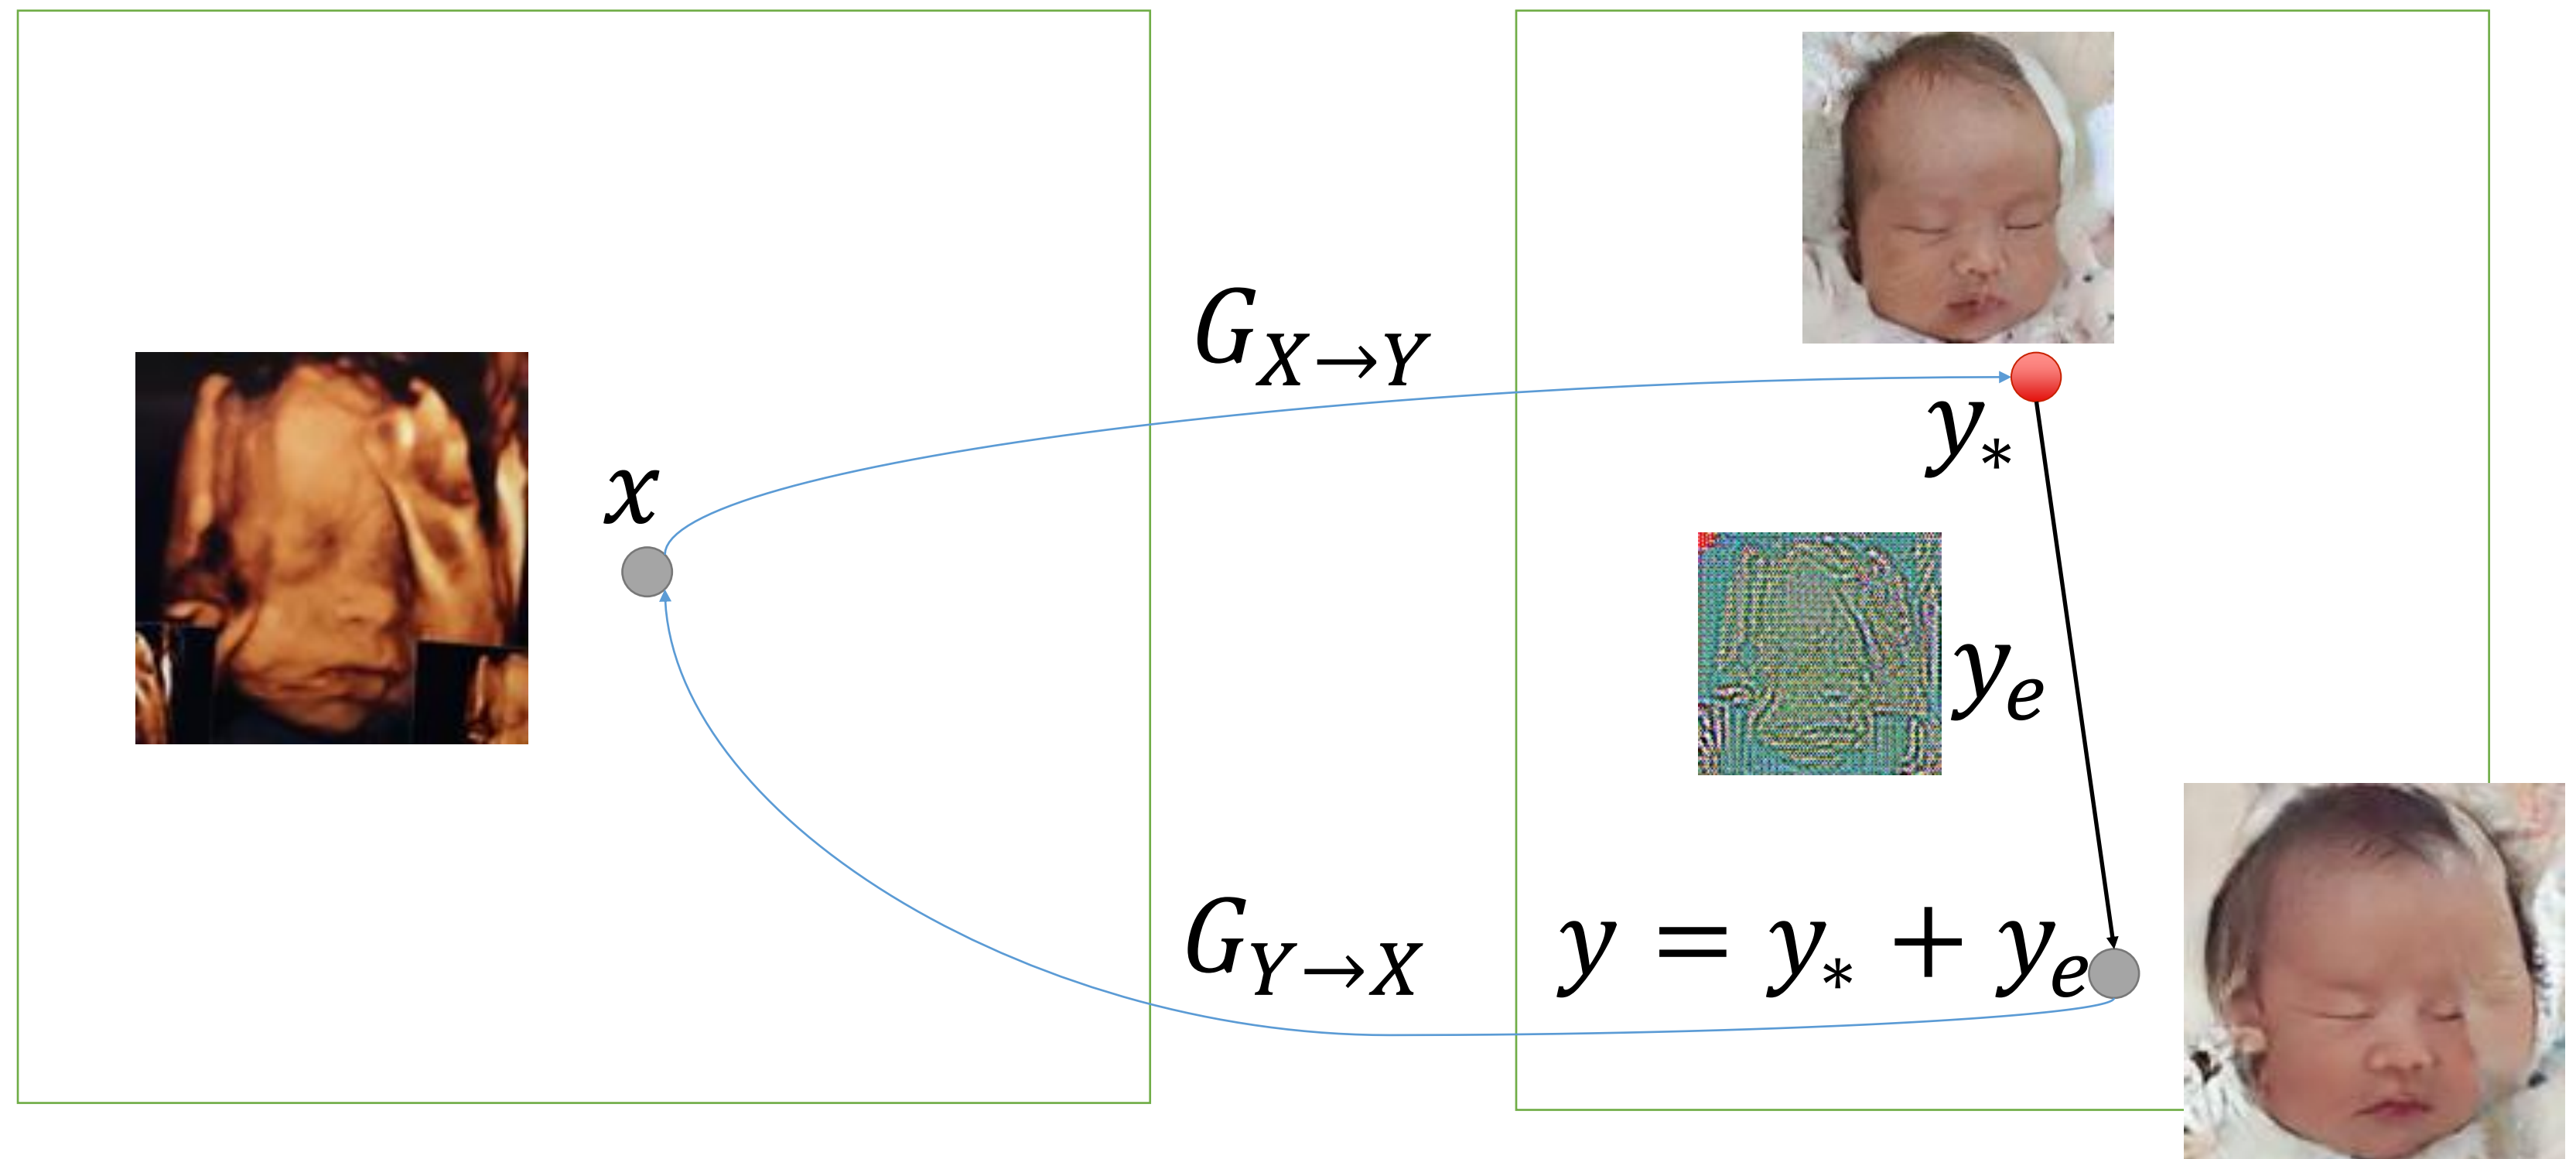
가려지고 왜곡된 부분을 error term으로 분리

타겟 도메인에서 아기 얼굴 이미지(y_*)와 에러 이미지(y_e)를 분해하여 표현

X (입체 초음파)

Y (아기 실사)


- x : 관측된 입체 초음파
- y_* : 얻고자 하는 아기 얼굴
- y_e : 에러 이미지
- y : 왜곡이 포함된 얼굴



3.2 Error term을 구하는 어려움

두 벡터를 더해서 한 지점에 이르는 방법은 무한히 많음

그 중에서 우리가 원하는 y_* 와 y_e 를 어떻게 구할 것 인가?




1. y_e 에 가려지고 왜곡된 부분만 포함시켜야 함
2. y_e 가 너무 크면 안됨

3.3 Gradient guided error term

X 도메인과 Y 도메인이 1:1로 맵핑된다면,
 y_e 에 상응하는 벡터 x_e 가 X 도메인에도 존재함

X (입체 초음파)

Y (아기 실사)



3.3 Gradient guided error term

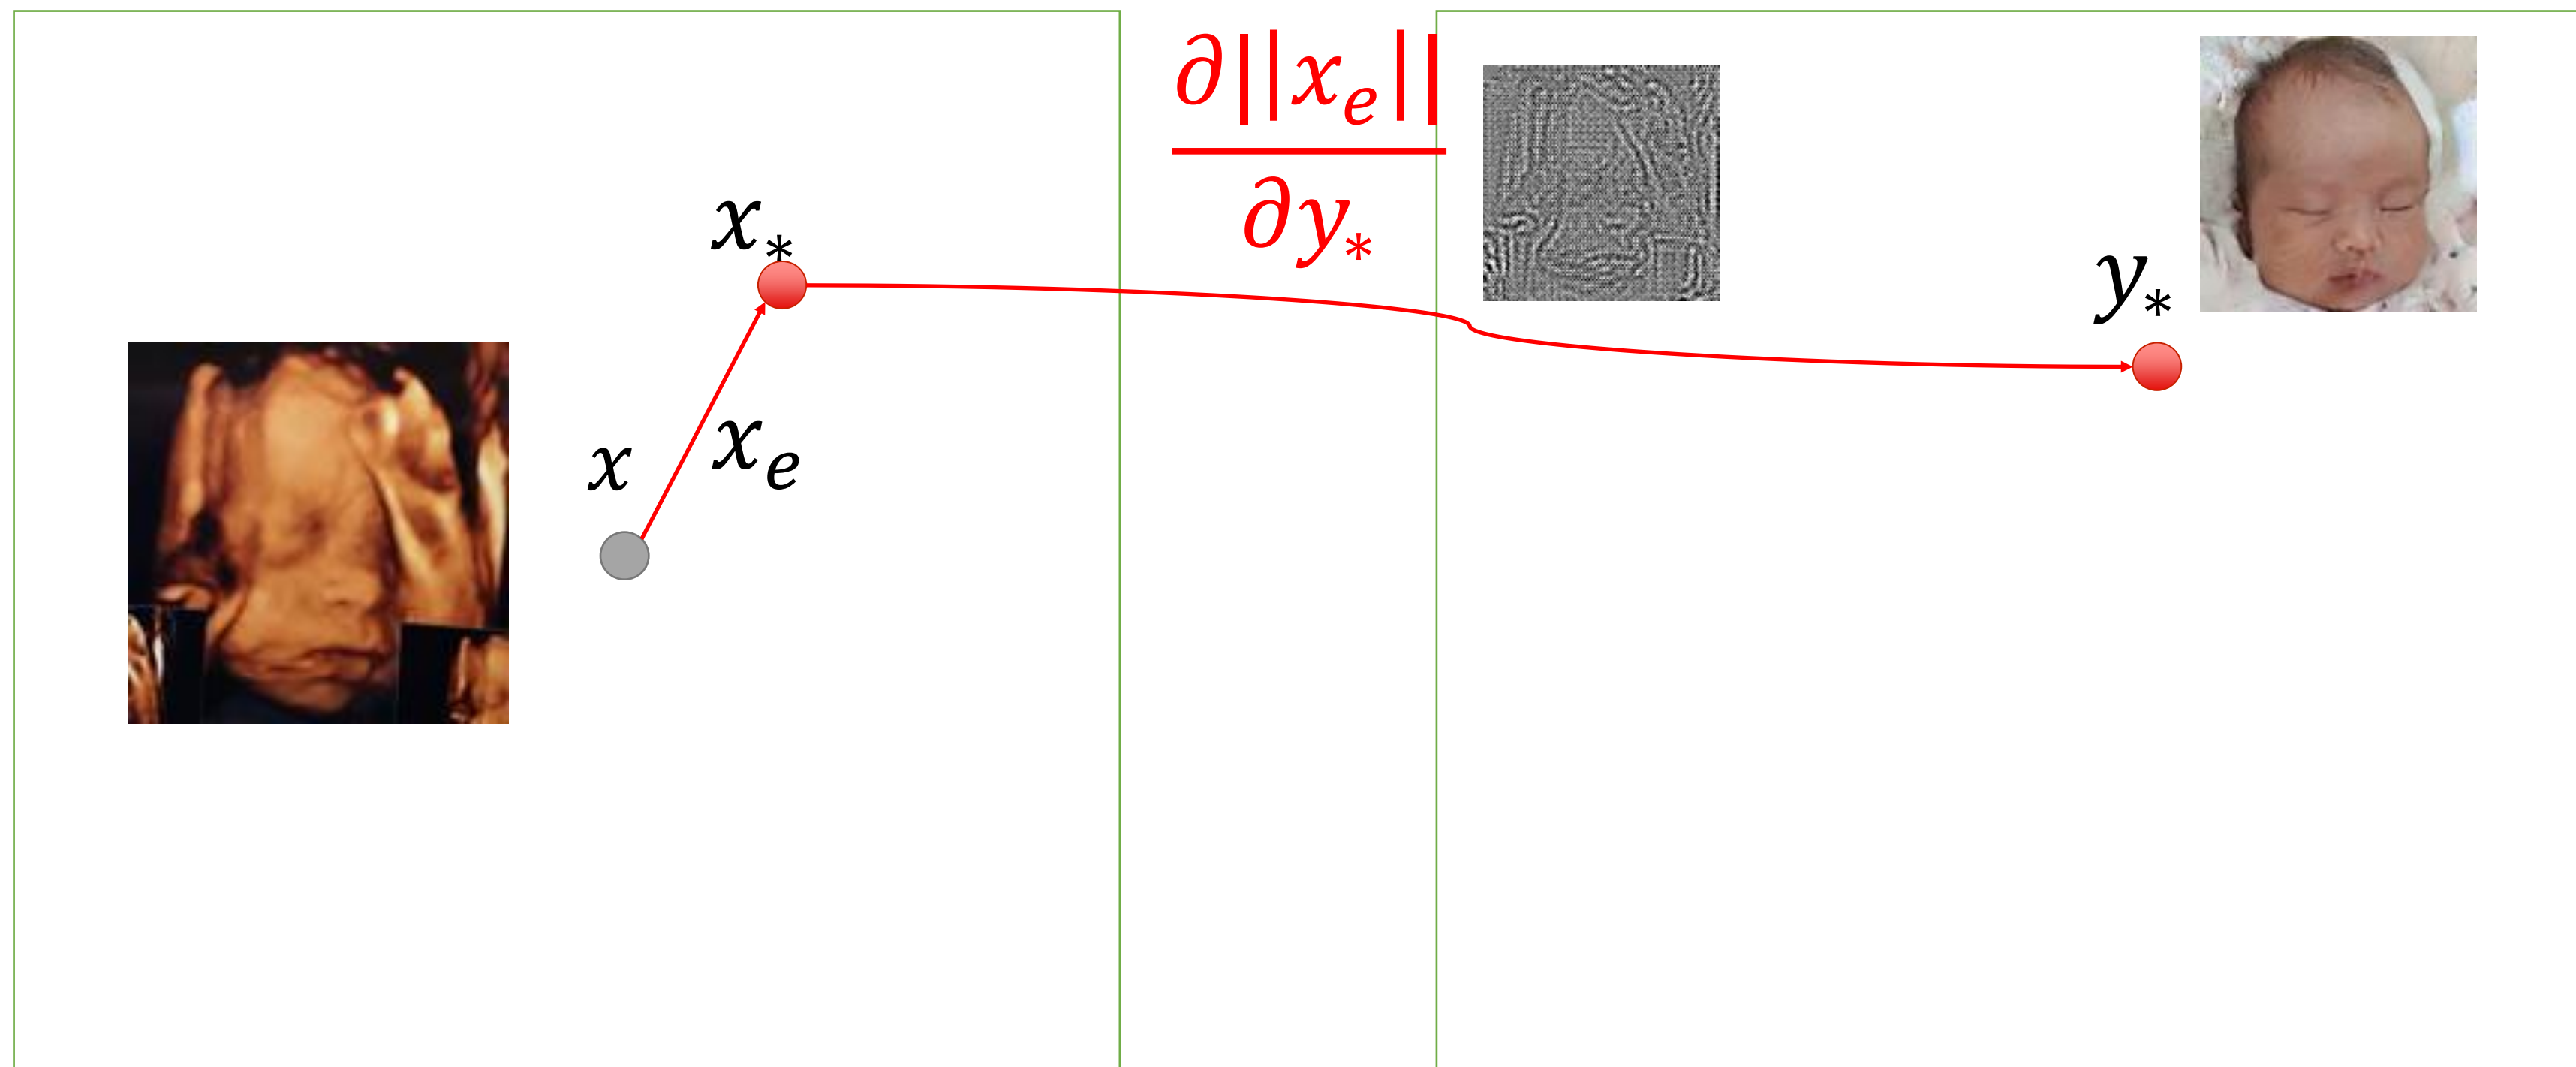
X 도메인의 오차 $\|x_e\|$ 를 y_* 로 미분하면,

- 이미지의 어느 부분이 오차에 크게 기여하는지 알 수 있고,
- 미분 값의 절대치가 큰 부분에 가려짐과 왜곡이 존재하지 않을까?

X (입체 초음파)

gradient

Y (아기 실사)



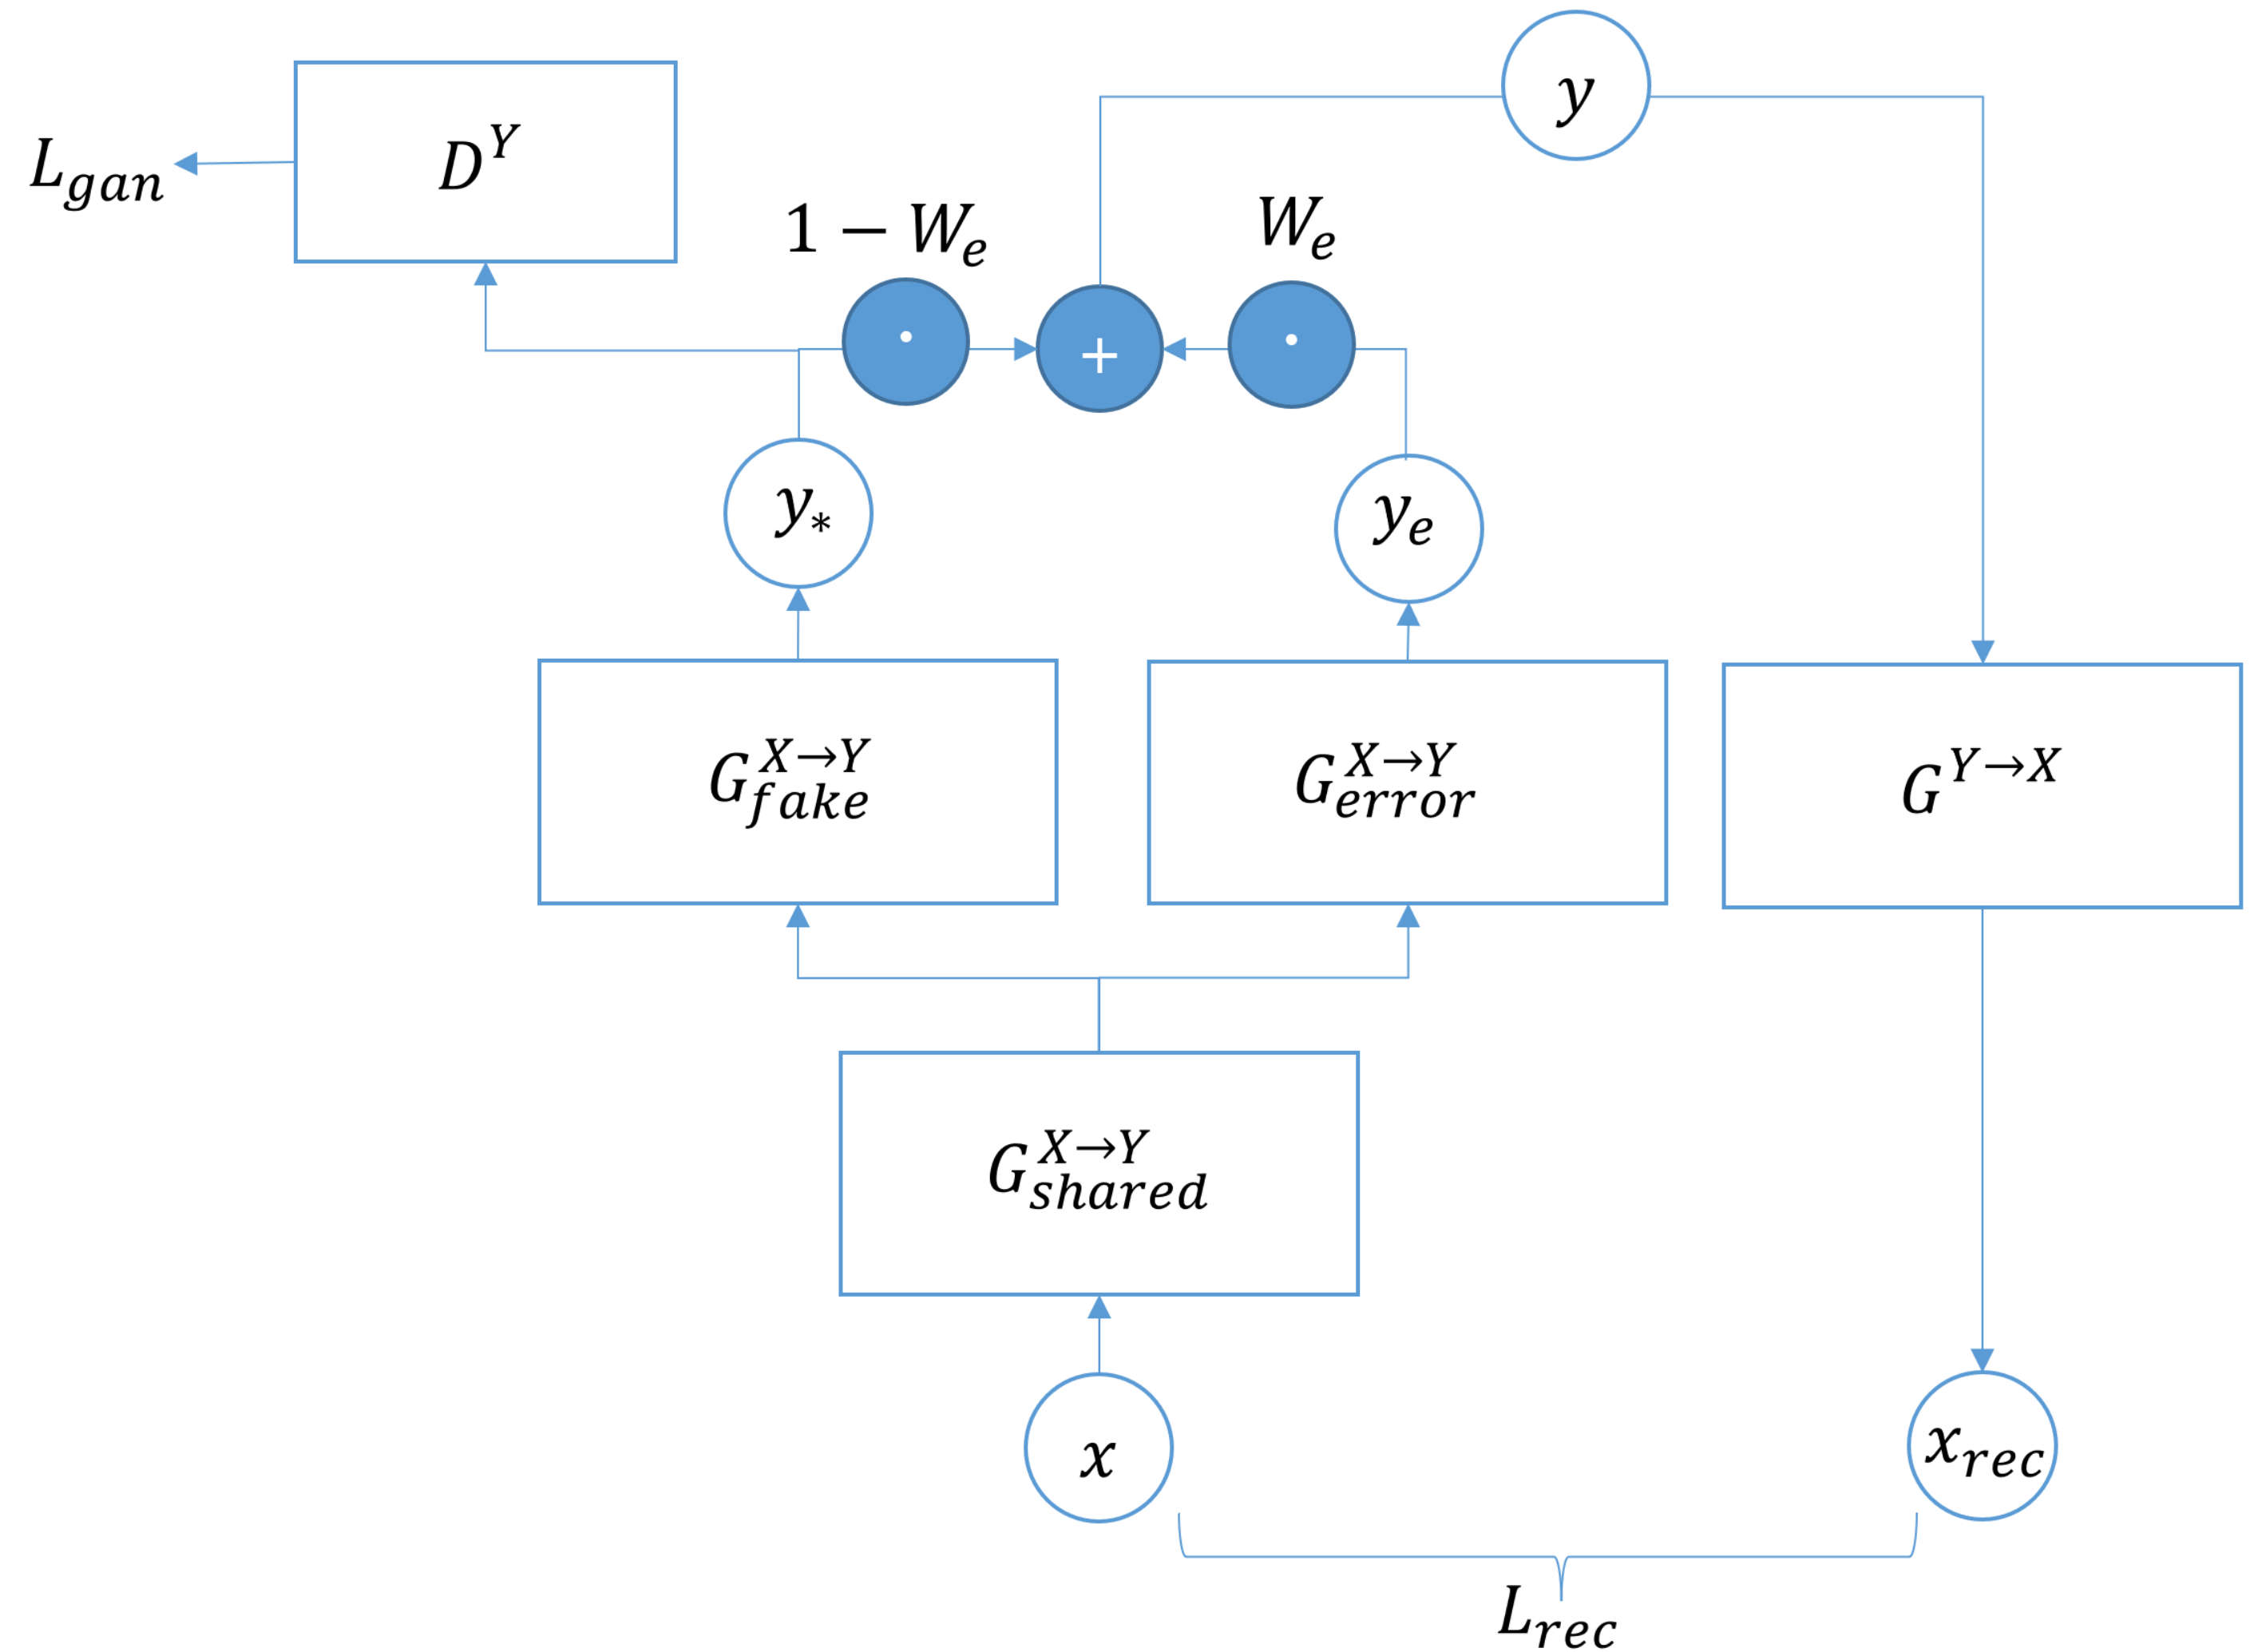
3.4 Gradient-guided error term GAN(GET-GAN)

GET-GAN = CycleGAN + gradient weight + error term

3.4 Gradient-guided error term GAN(GET-GAN)

GET-GAN의 구조

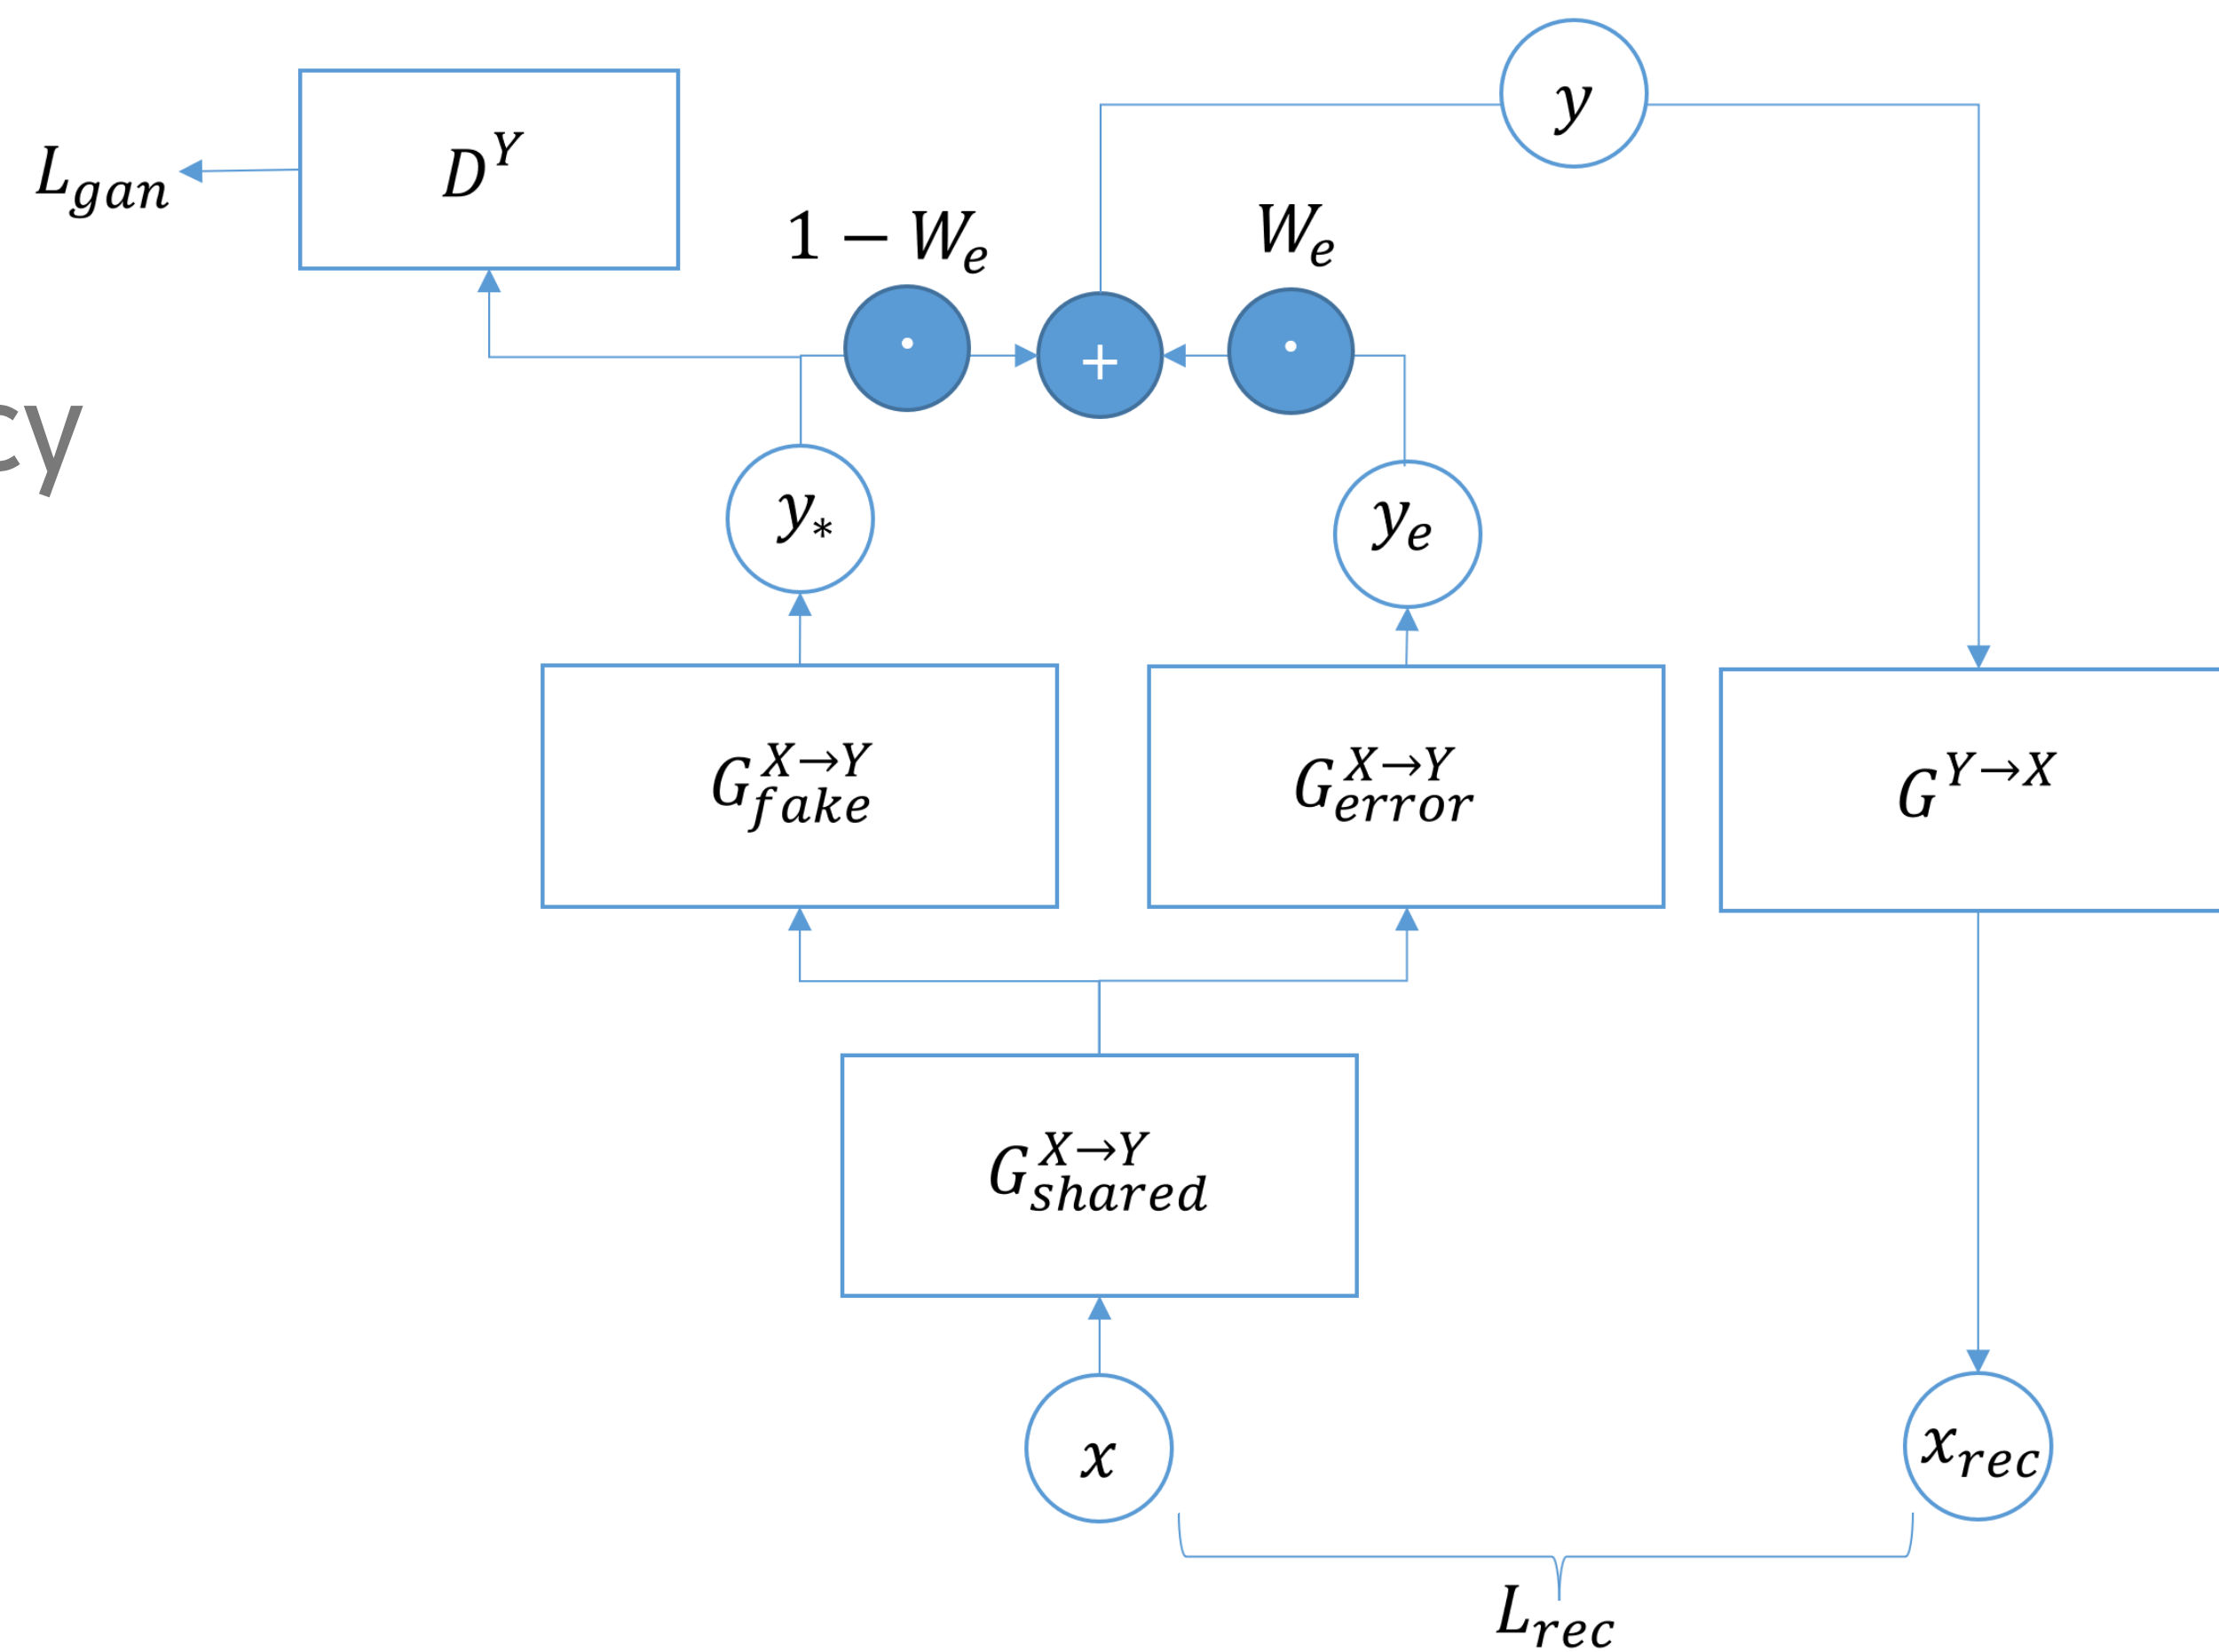
- $G_{shared}^{X \rightarrow Y}$: 입체 초음파의 특징 추출
- $G_{fake}^{X \rightarrow Y}$: 온전한 아기 얼굴 y_* 를 생성
- $G_{error}^{X \rightarrow Y}$: error term y_e 를 생성
- $G^{Y \rightarrow X}$: 반대 방향의 변환 수행
- D^Y 와 D^X : 각 도메인의 판별자



3.4 Training GET-GAN : five steps

GET-GAN의 학습은 다섯 단계로 이뤄짐

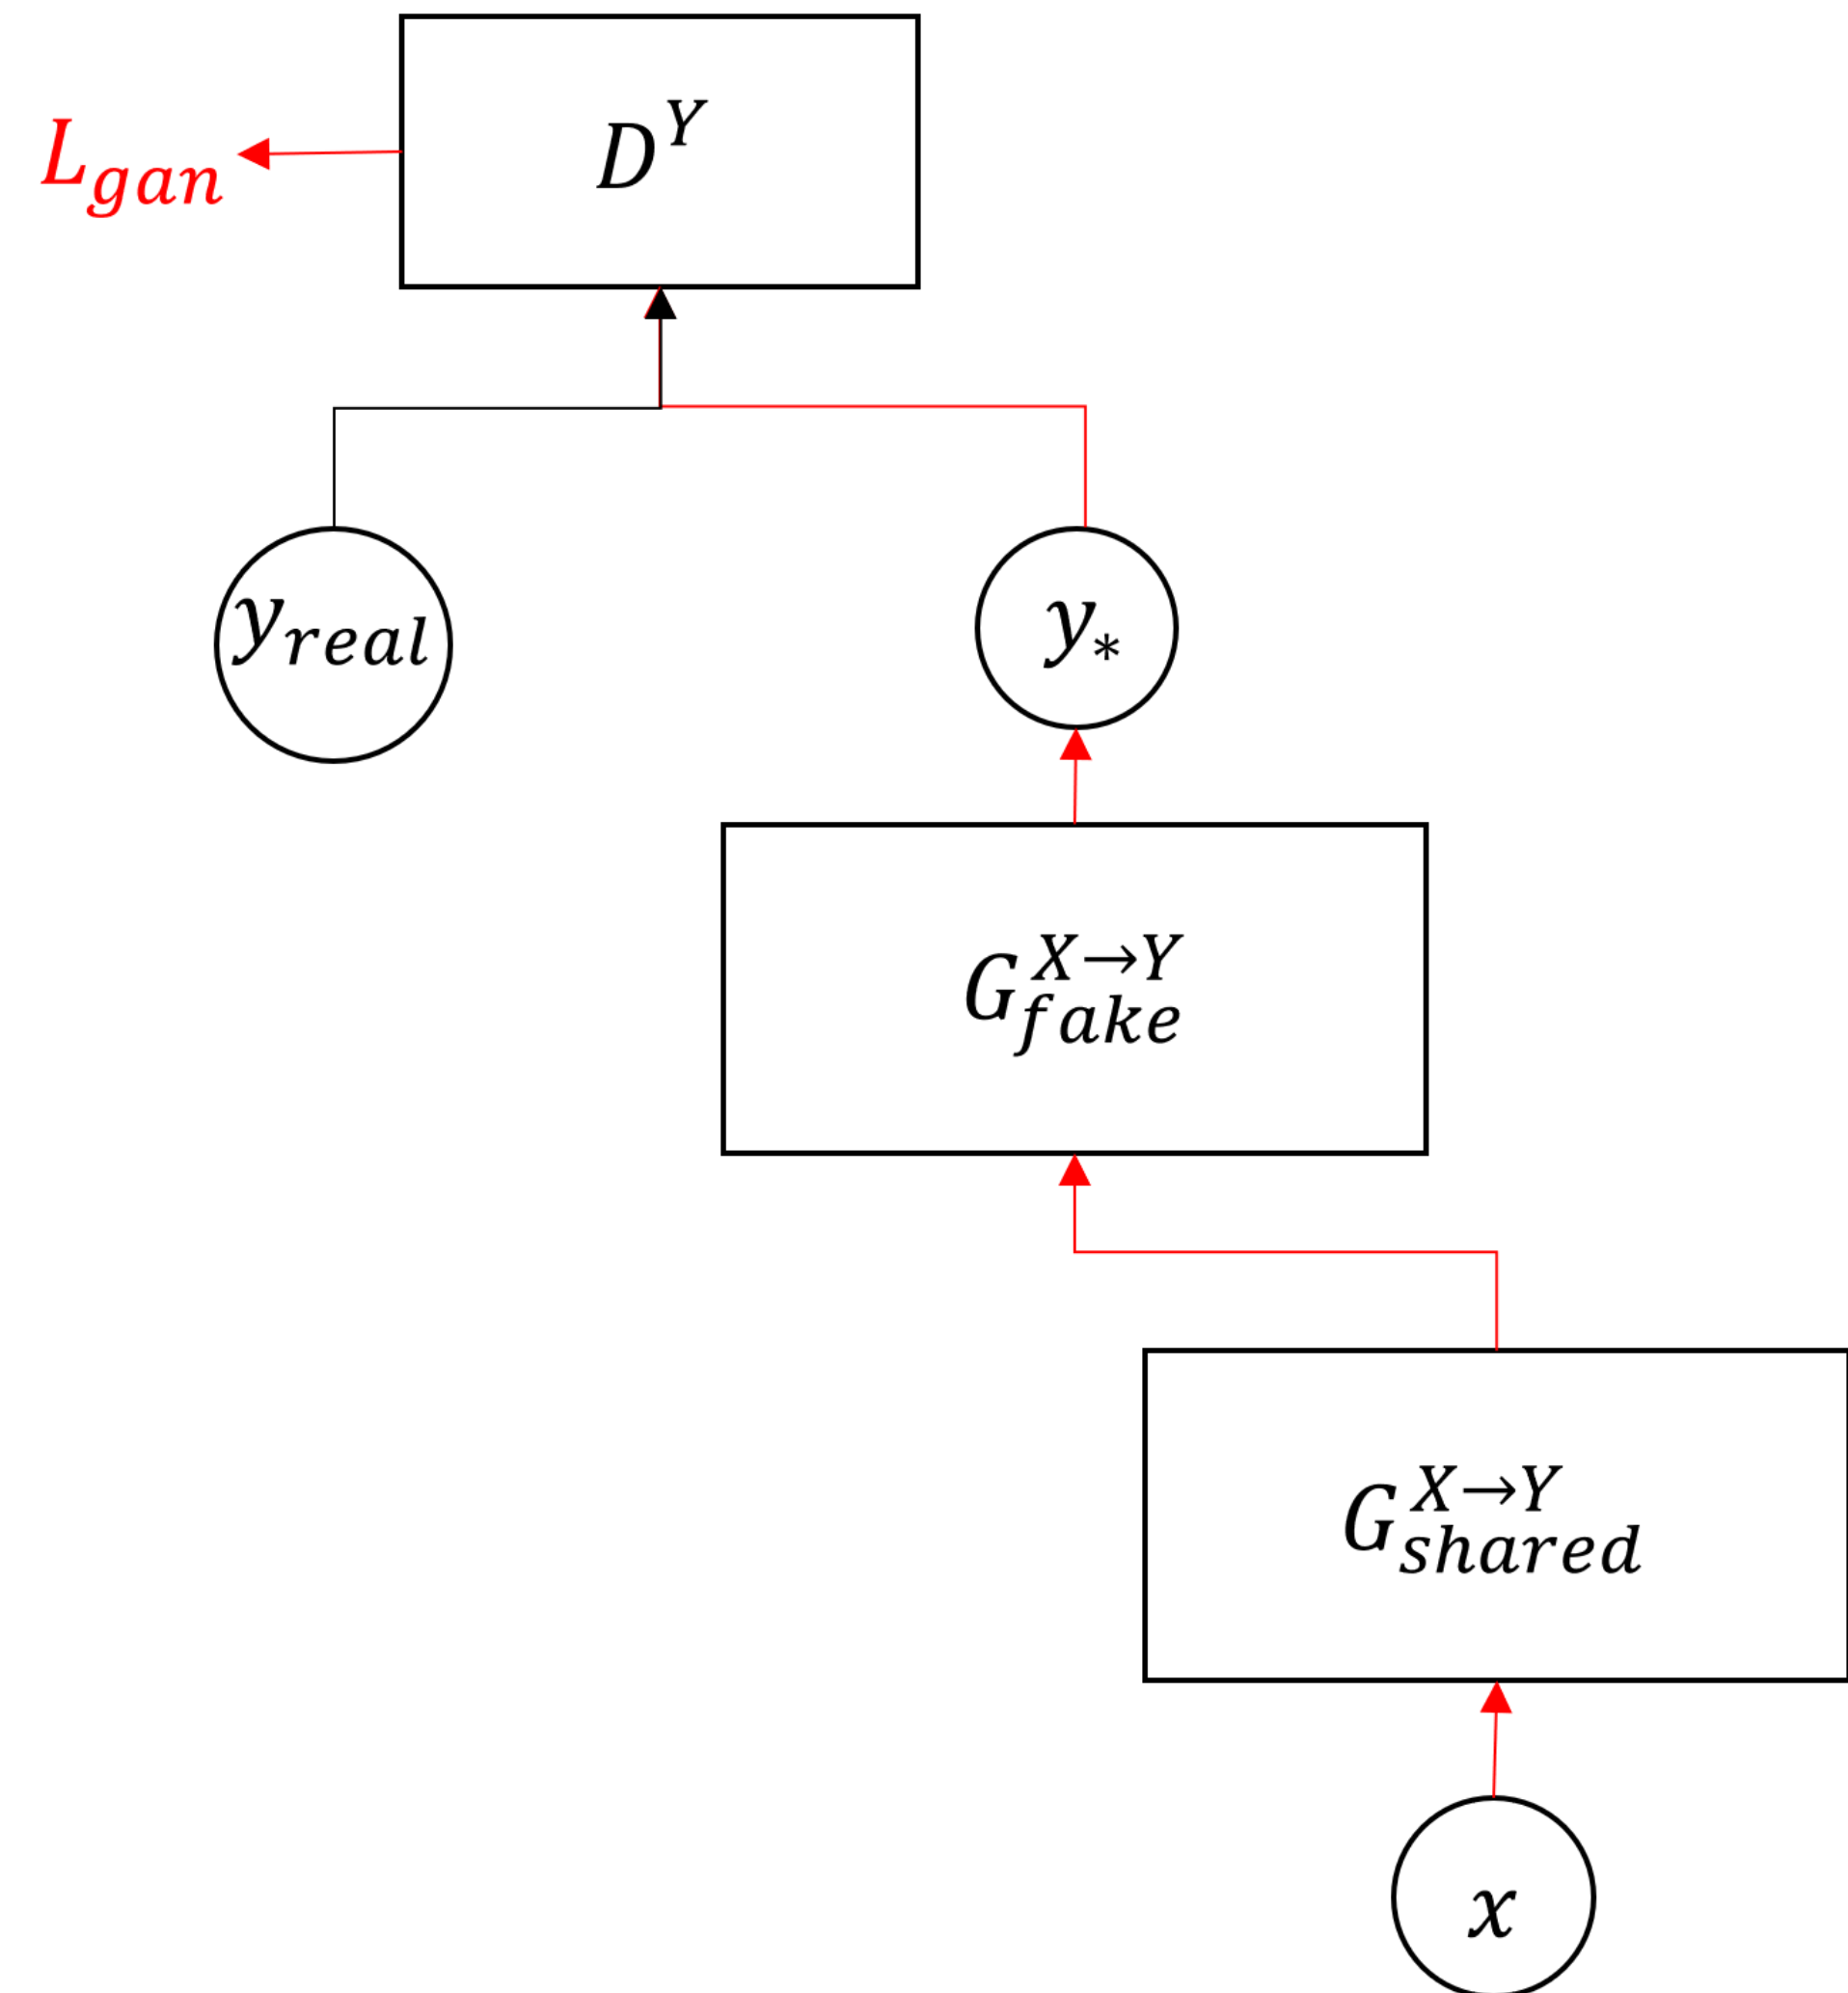
1. y_* 를 구하고 생성자 업데이트
2. Gradient weight를 구함
3. Error term을 포함한 cycle consistency
4. 역변환 Y to X 를 학습
5. Identity loss를 최소화



3.4 Training GET-GAN (1/5)

y_* 를 구하고, 일반적인 GAN의 loss function L_{gan} 을 최소화하도록

$G_{fake}^{X \rightarrow Y}$ 와 $G_{shared}^{X \rightarrow Y}$ 를 업데이트함



3.4 Training GET-GAN (2/5)

Gradient weight W_e 를 구함

1. $L_{rec}(x, G^{Y \rightarrow X}(y^*))$ 로부터 y^* 까지 역전파하여 g 를 구함

$$g = \frac{\partial L_{rec}}{\partial y^*}$$

- y^* 를 이상적인 아기 얼굴 이미지로 가정하면

- g 를 통해 y^* 의 어떤 부분이

오차에 기여하는지 알 수 있음

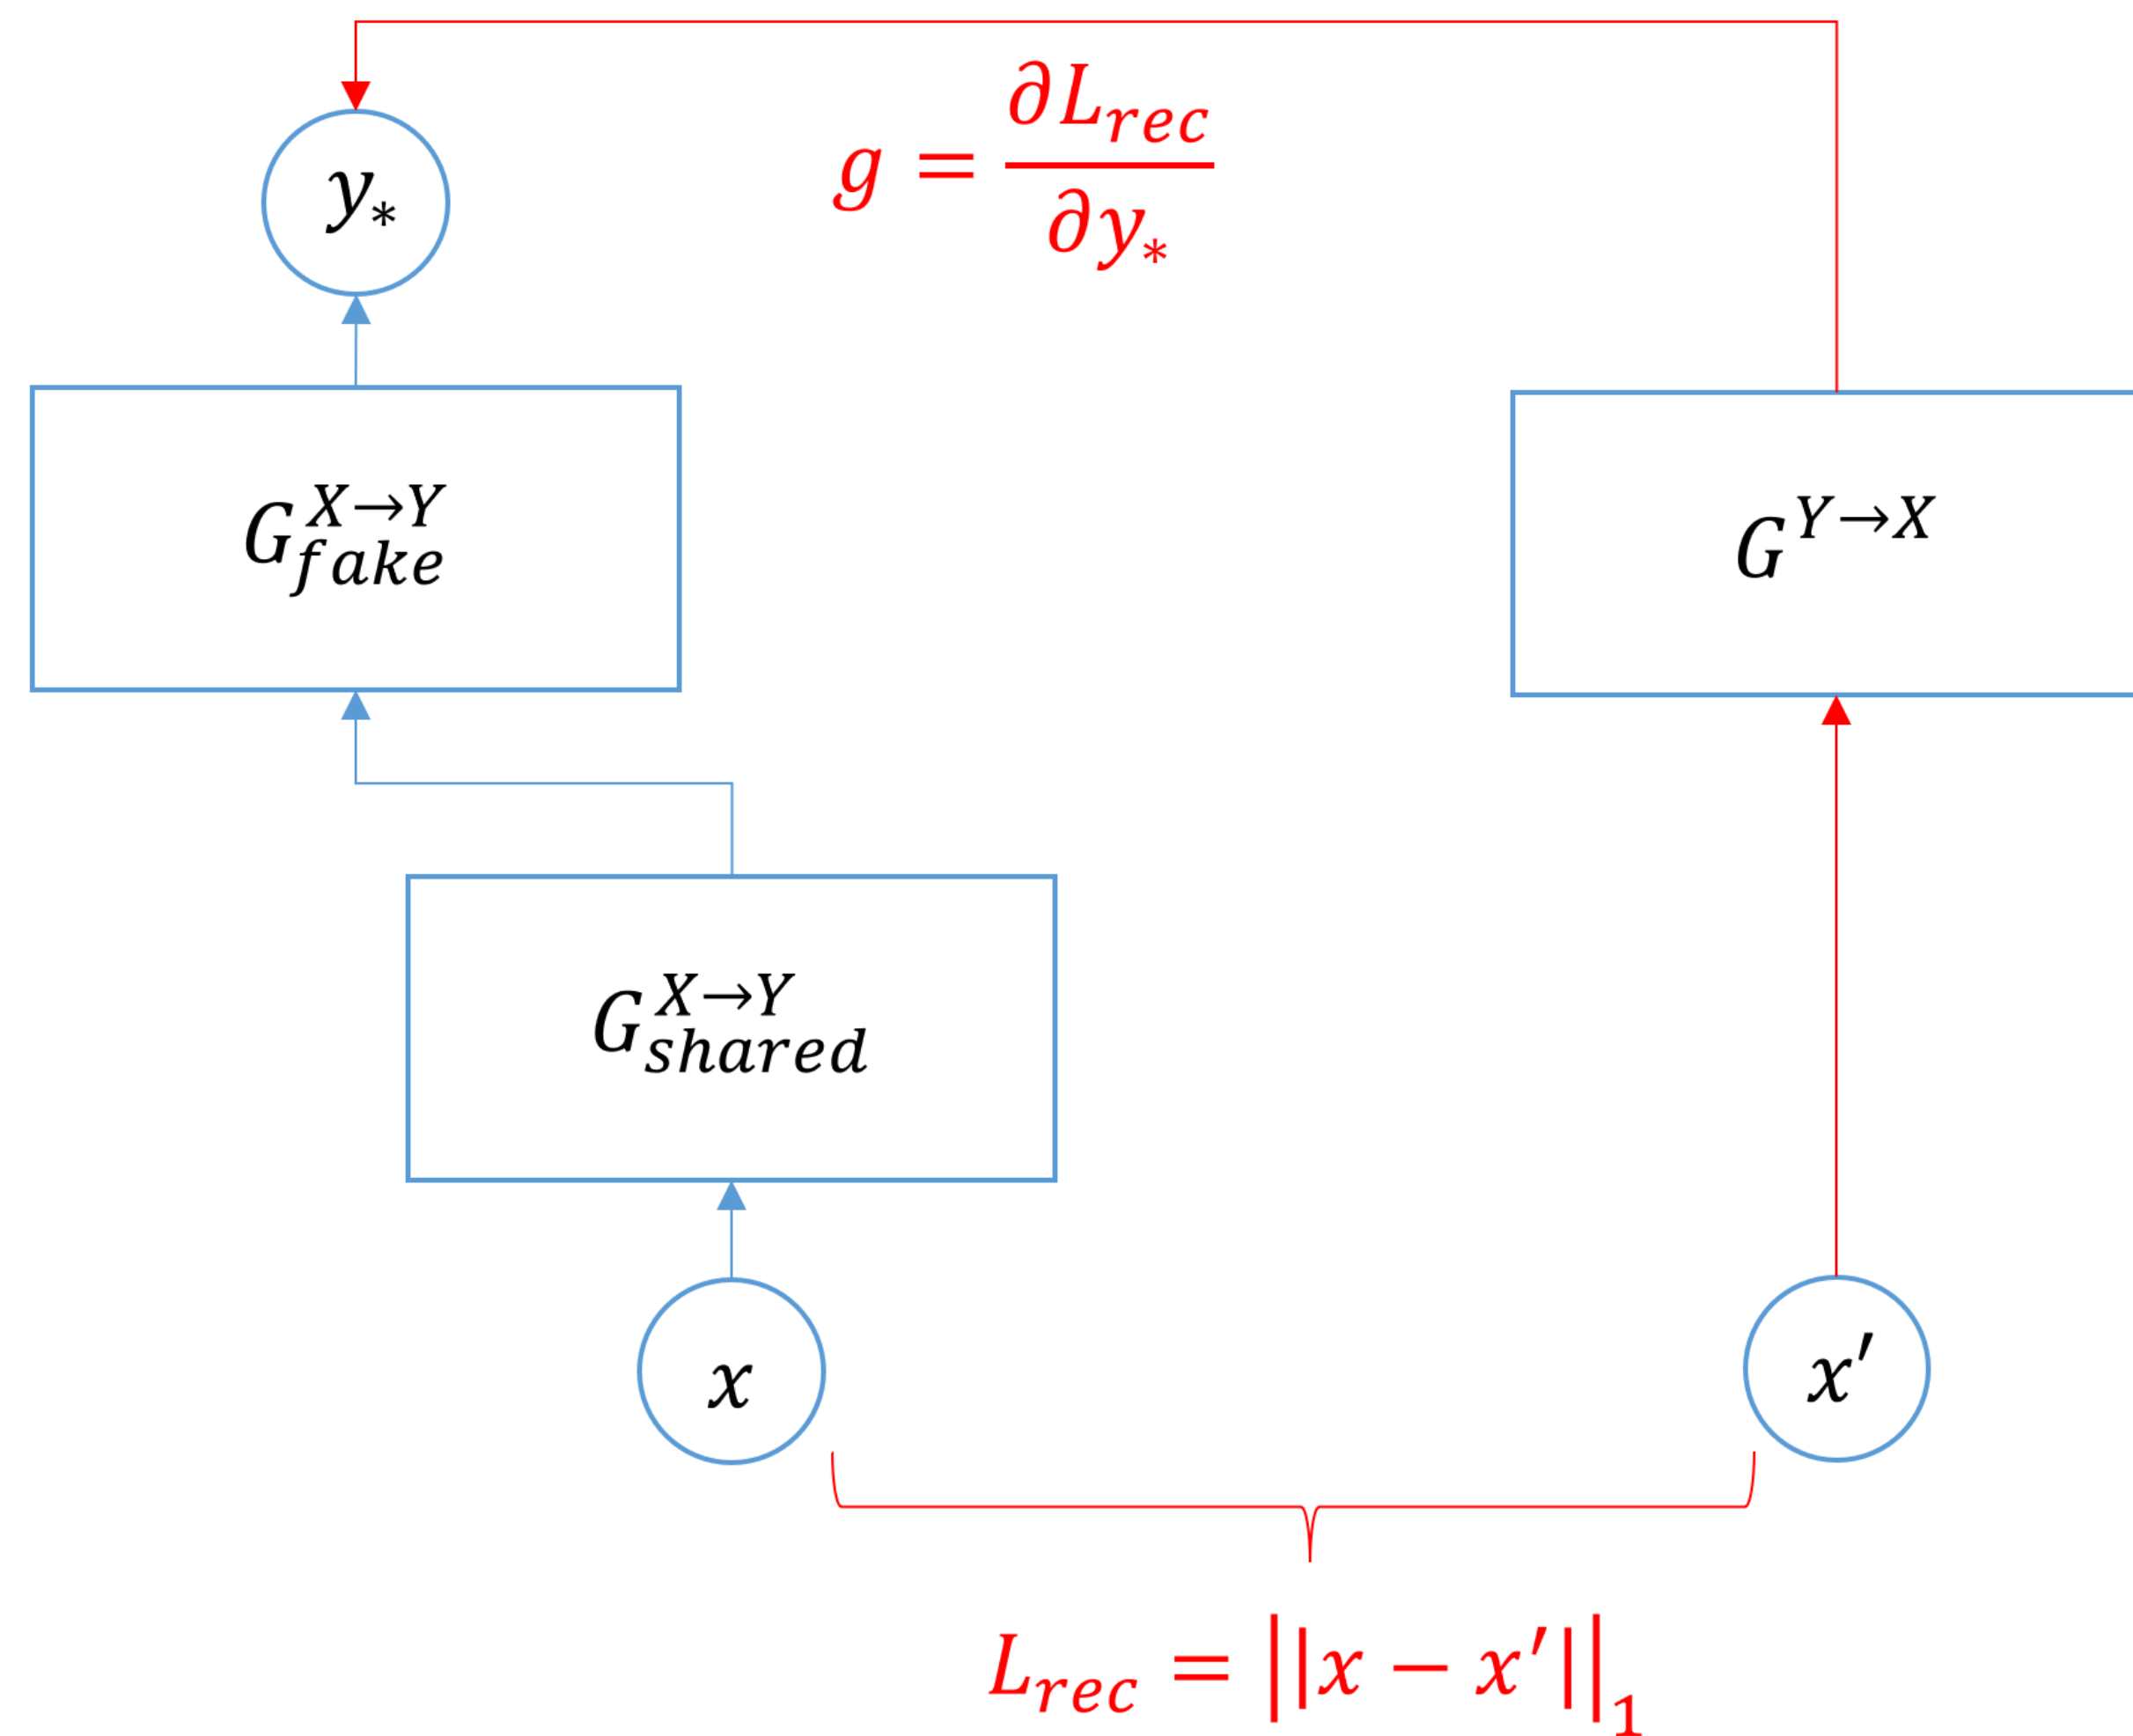
2. g 의 각 채널을 정규화 함

$$z_c = \left| \frac{\mu_c - g_c}{\sigma_c + \epsilon} \right|, \text{ where } c \text{ is } (R, G, B)$$

3. 정규화된 이미지에 sigmoid를 적용하여

[0.5, 1] 범위로 조정

$$\text{Gradient weight } W_e = \text{sigmoid}(z)$$



3.4 Training GET-GAN (3/5)

Gradient weight W_e 를 가중치로 사용하여 cycle consistency loss 최소화

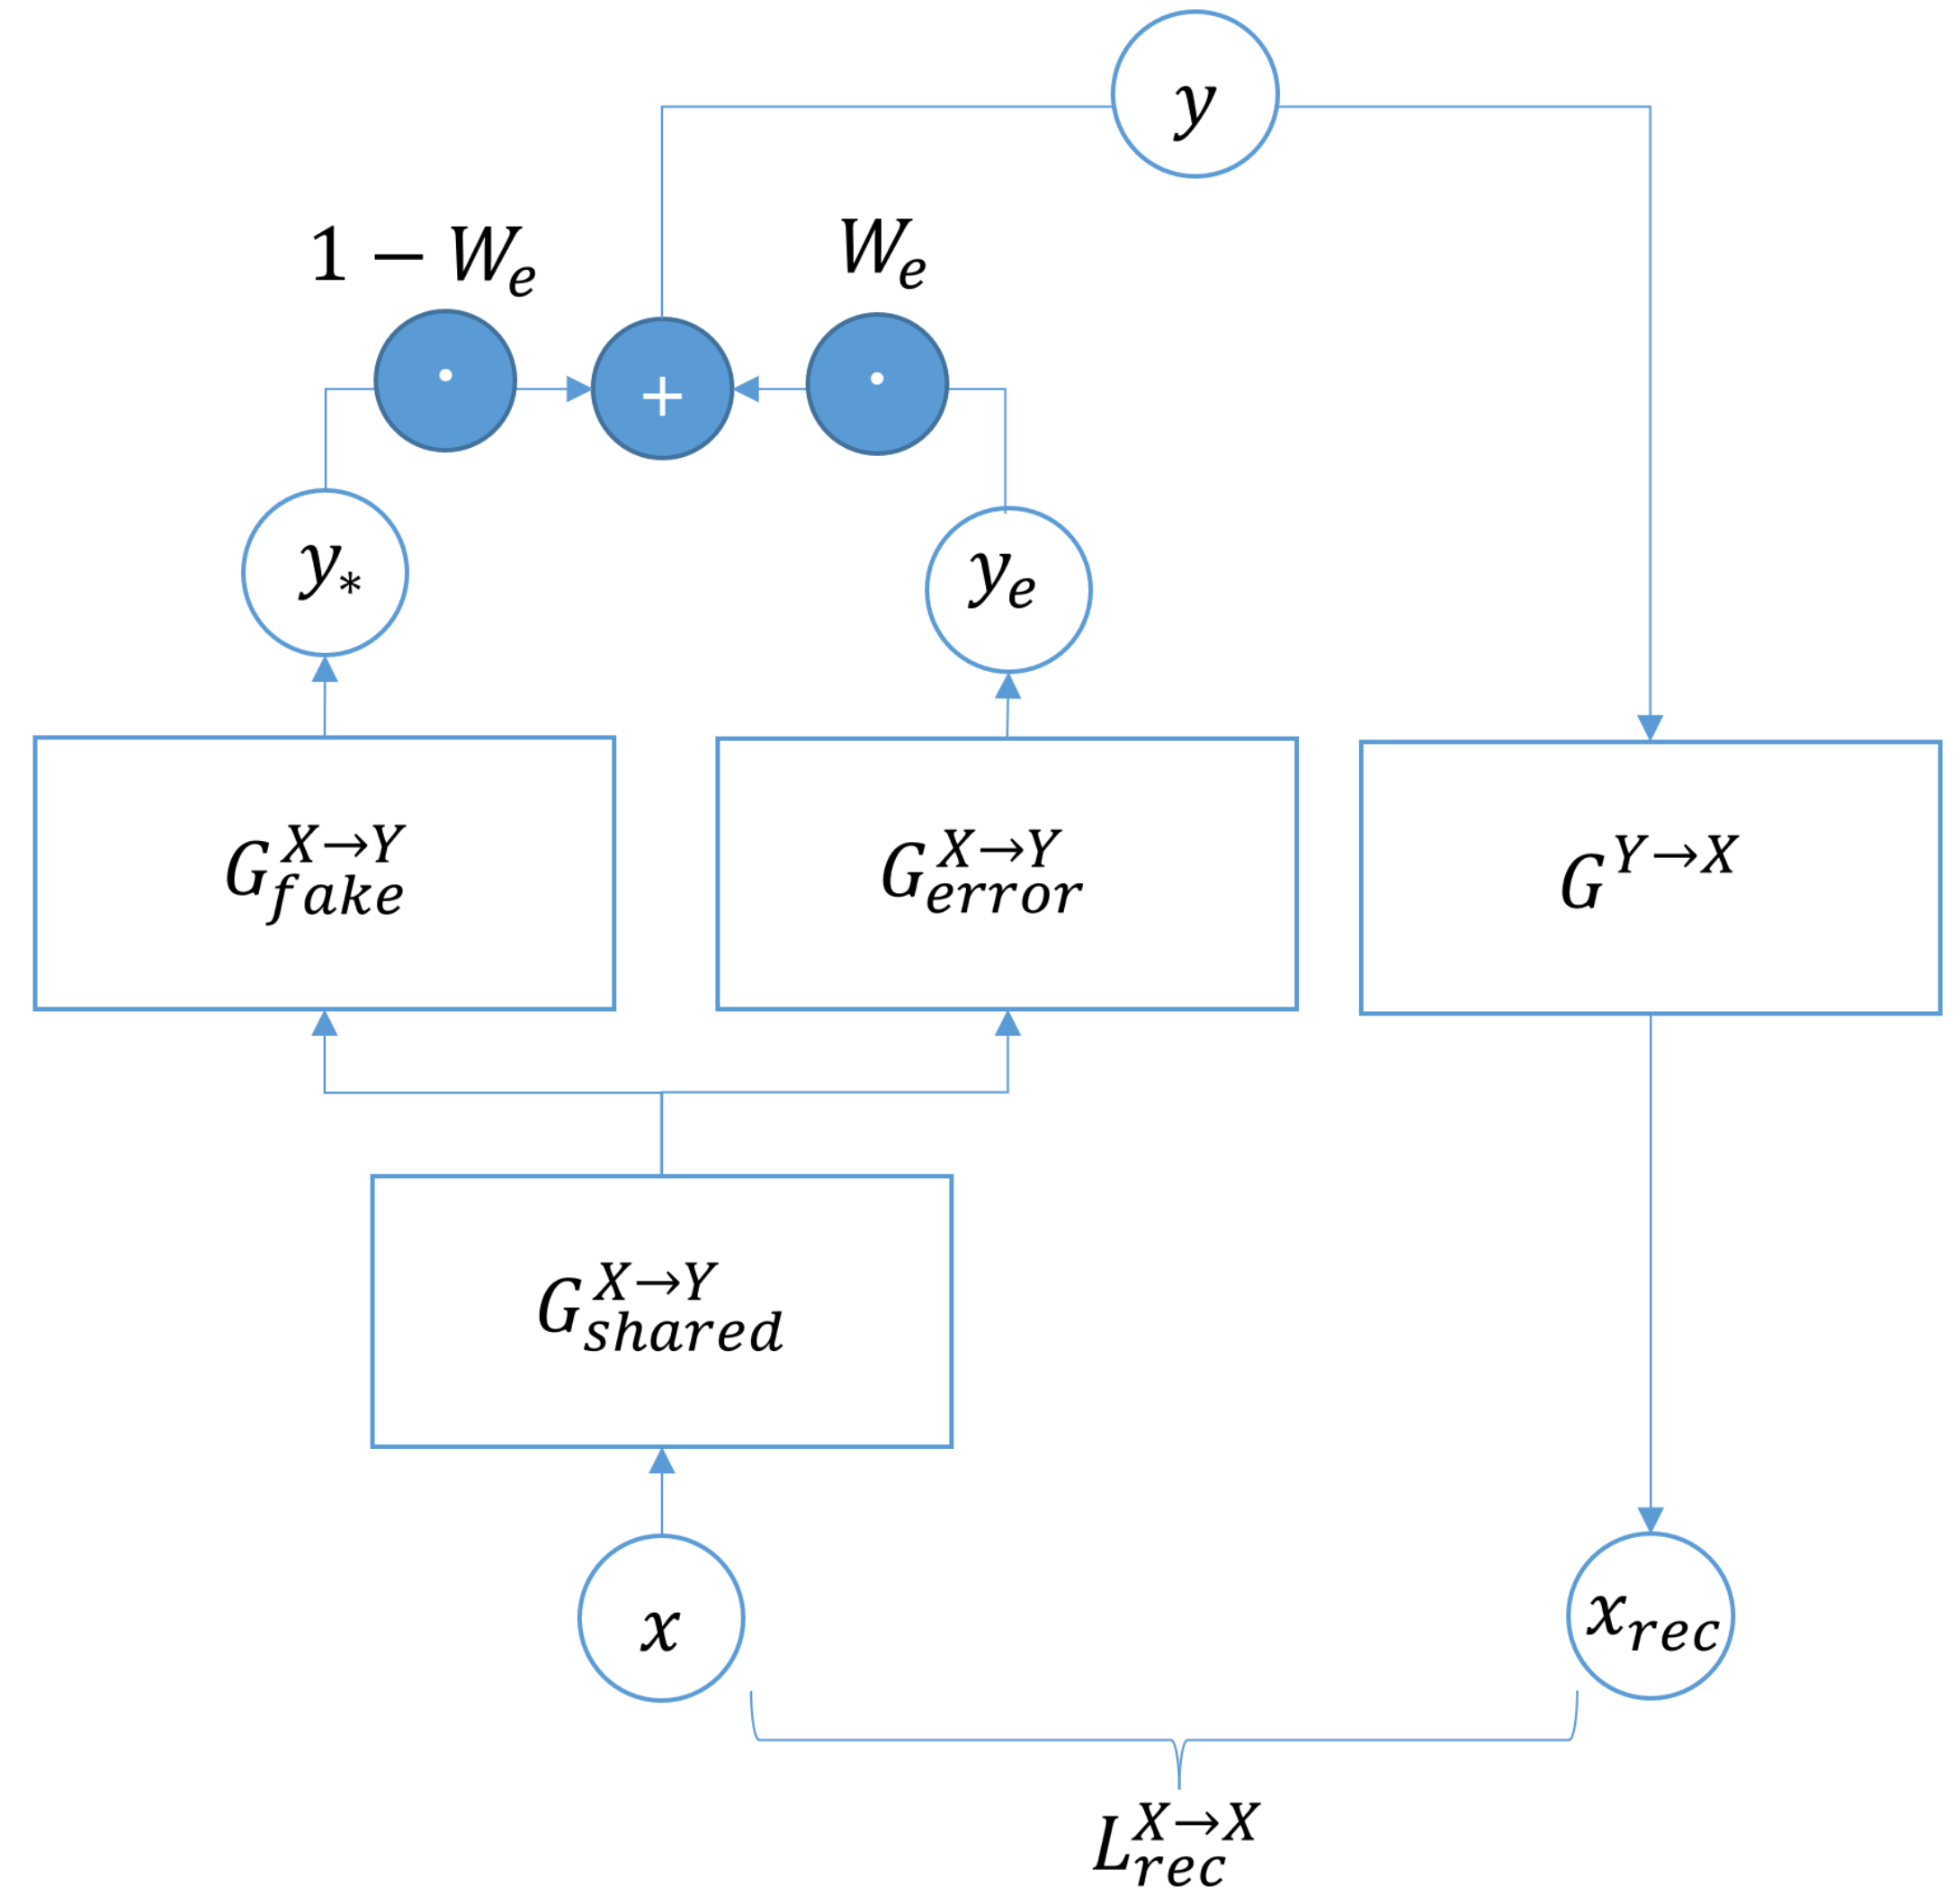
- $G^{X \rightarrow Y}$ 와 $G^{Y \rightarrow X}$ 를 업데이트

$$L_{rec}^{X \rightarrow X}(x, G^{Y \rightarrow X}(y)) = \|x - G^{Y \rightarrow X}(y)\|_1$$

, where $y = (1 - W_e)y_* + W_e y_e$

- W_e 는 오차가 큰 영역에 큰 가중치를 줌

- 따라서 오차를 유발하는 특징을 네트워크가 분리하도록 학습



3.4 Training GET-GAN (4/5)

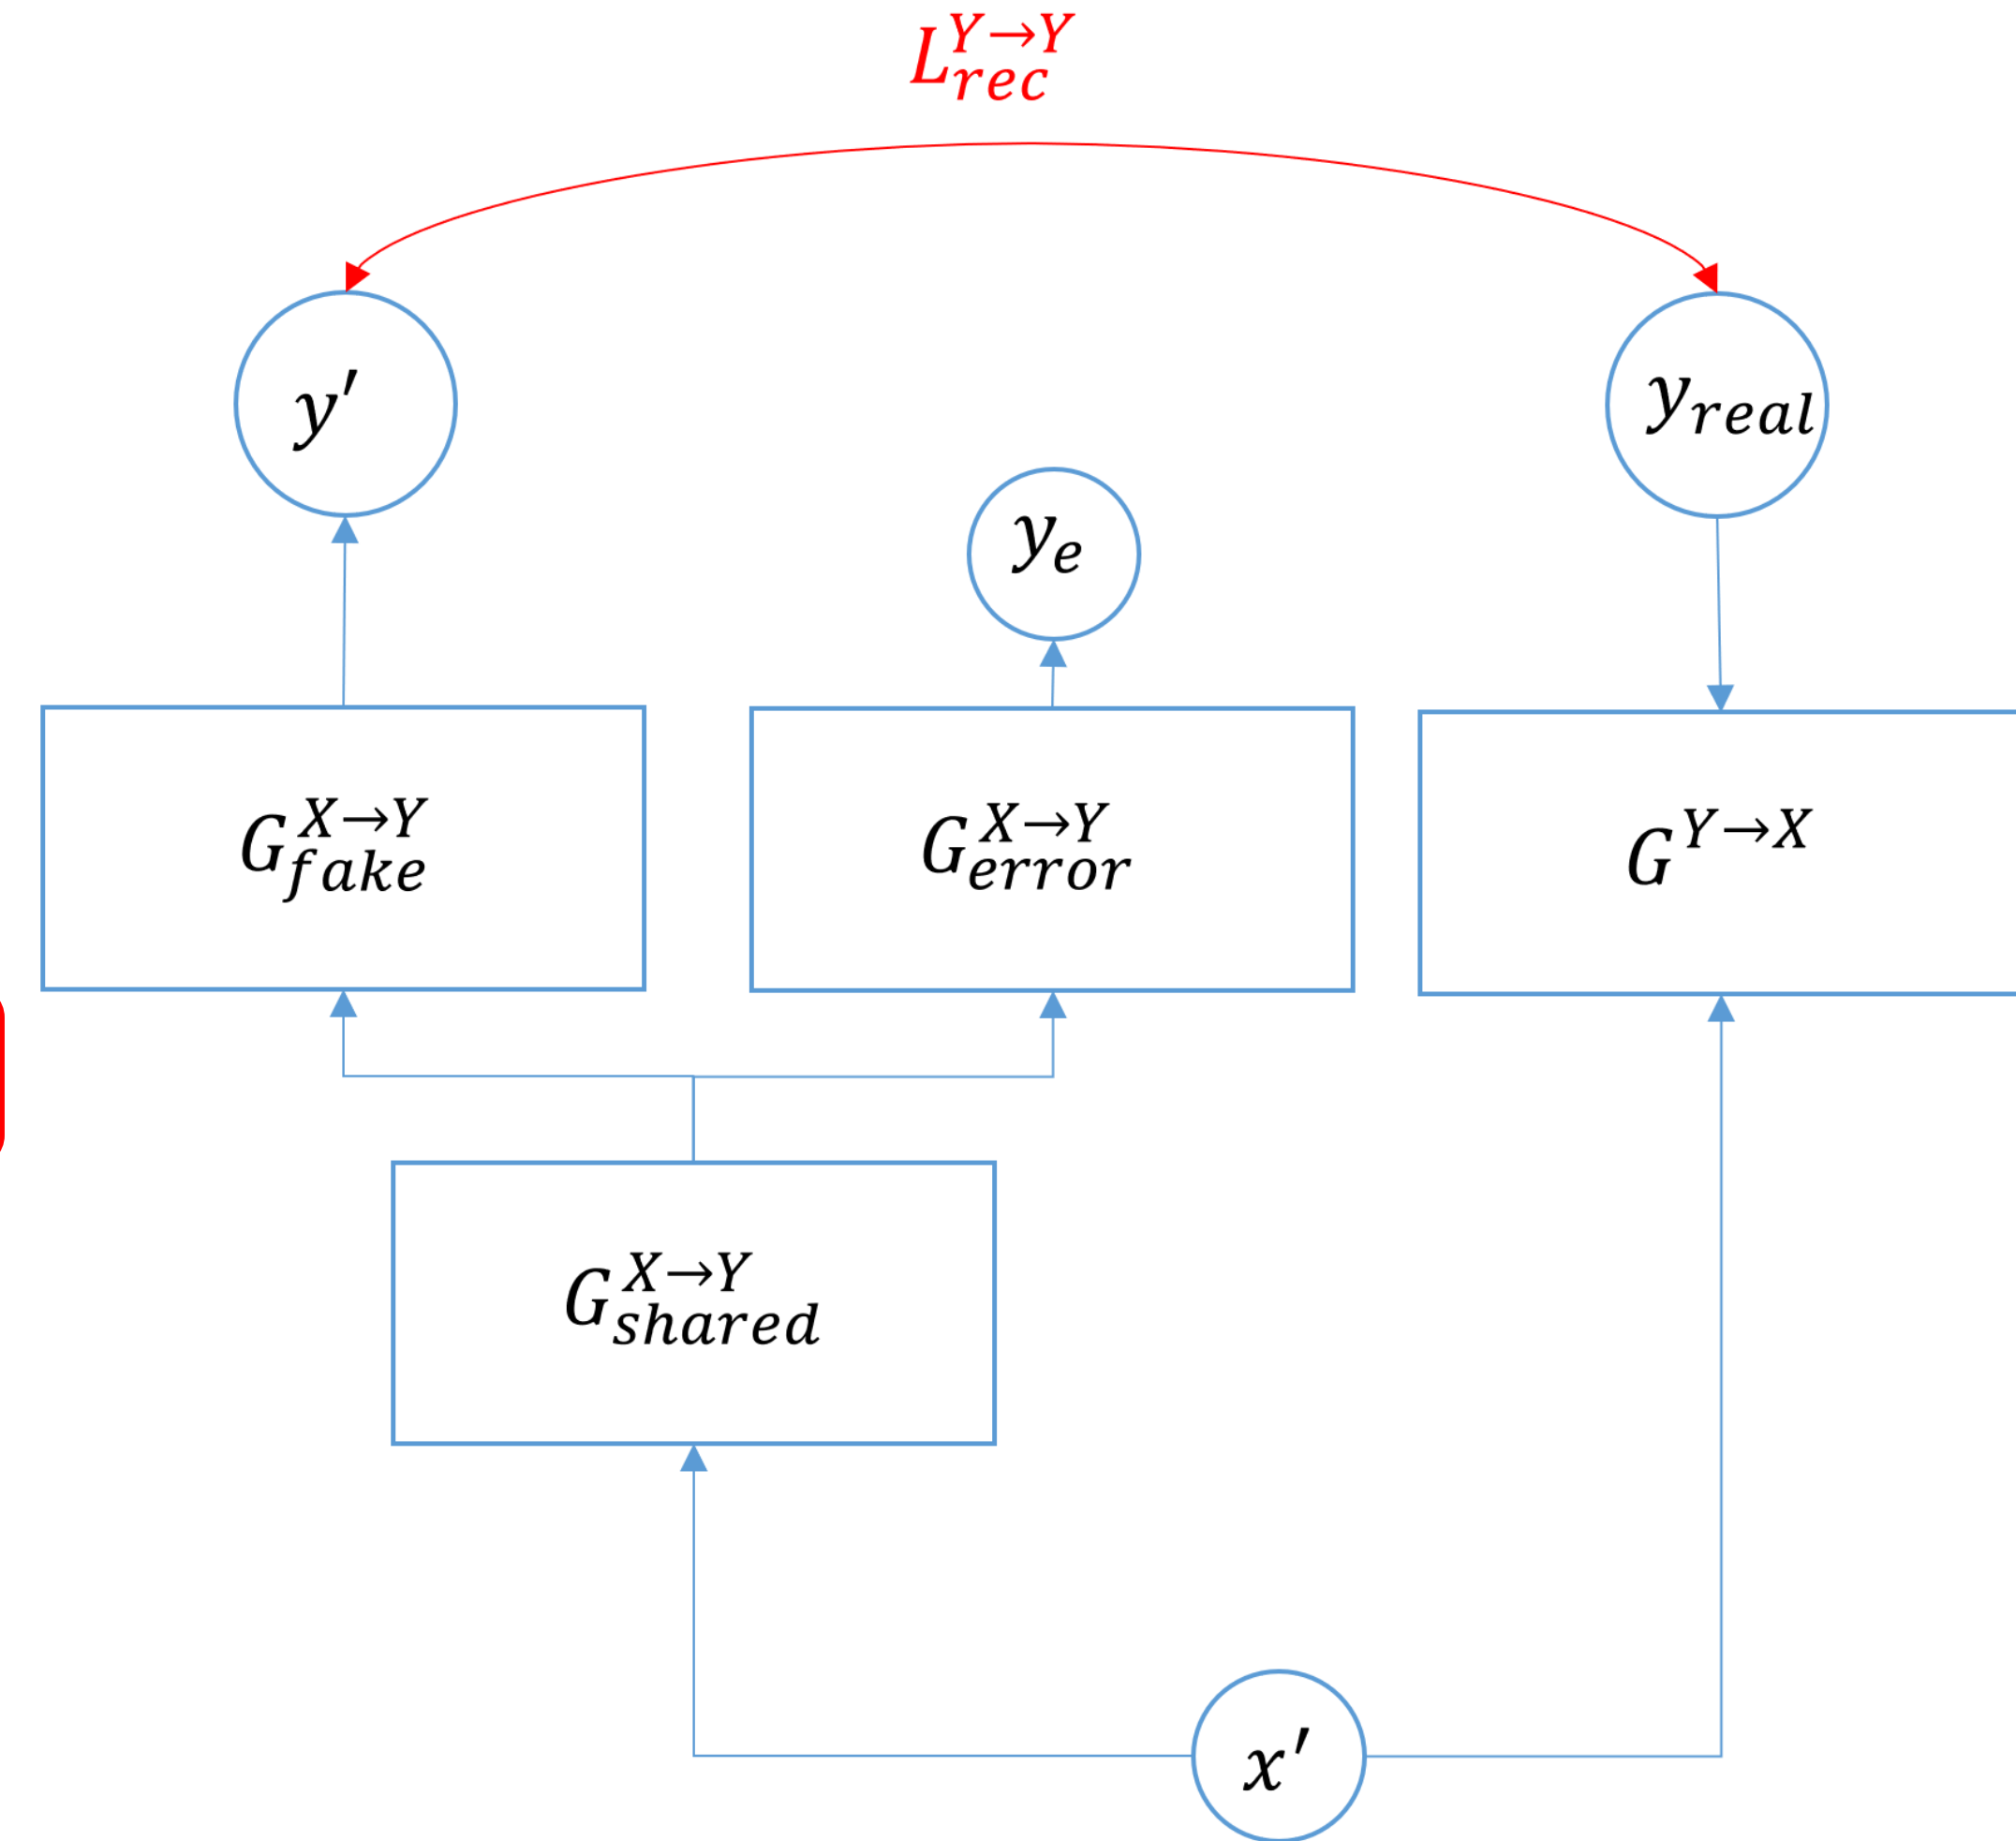
역변환 Y to X 를 학습

1. 역방향으로 cycle consistency loss를 최소화
 y_{real} 에 오류를 유발하는 특징이 없으므로
 y_e 는 0이 되어야 함

$$L_{rec}^{Y \rightarrow Y}(y_{real}, y') = \lambda_{rec} \|y_{real} - y'\|_1 + \lambda_{error} \mu(|y_e|)$$

y_e 가 0이 되도록 제약

2. 일반적인 GAN loss를 이용하여
 $G^{Y \rightarrow X}$ 와 두 판별자를 학습



* λ_* 는 적절히 선택한 상수

3.4 Training GET-GAN (5/5)

Identity loss 최소화

타겟 도메인의 특징을 최대한 유지하기 위한 과정

양방향으로 identity loss 최소화

y_{real} 에 오류를 유발하는 특징이 없으므로 y_e 는 0이 되어야 함

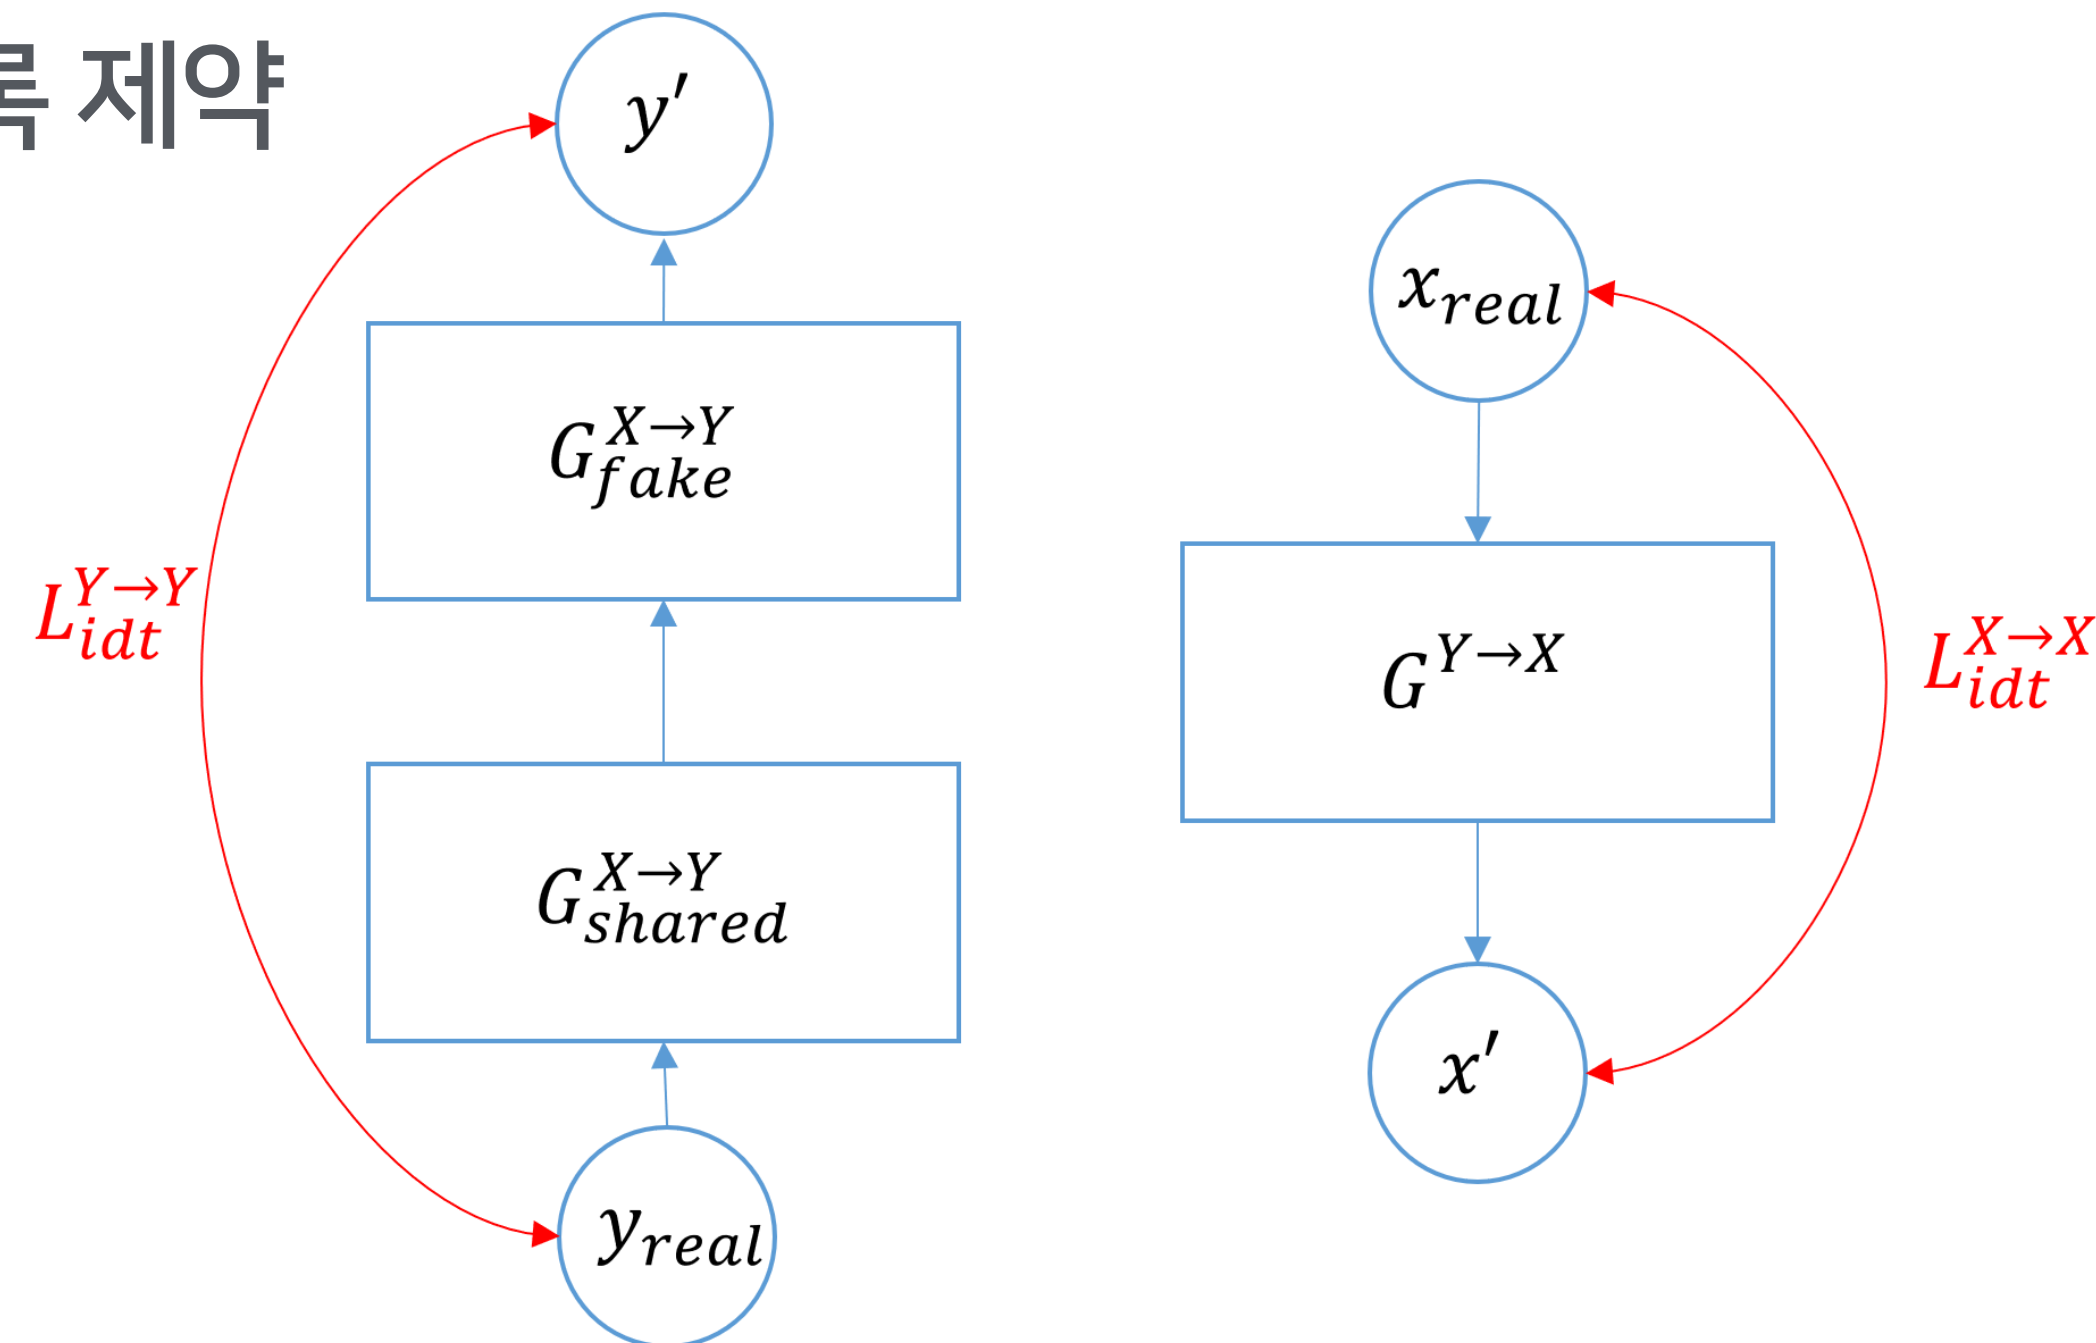
$L_{idt}^{Y \rightarrow Y}(y_{real}, G_{fake}^{X \rightarrow Y}(y_{real}))$ y_e 가 0이 되도록 제약

$$= \lambda_{idt} \|y_{real} - G_{fake}^{X \rightarrow Y}(y_{real})\|_1 + \lambda_{error} \mu(|y_e|)$$

$L_{idt}^{X \rightarrow X}(x_{real}, G_{fake}^{Y \rightarrow X}(x_{real}))$

$$= \lambda_{idt} \|x_{real} - G_{fake}^{Y \rightarrow X}(x_{real})\|_1$$

* λ_* 는 적절히 선택한 상수

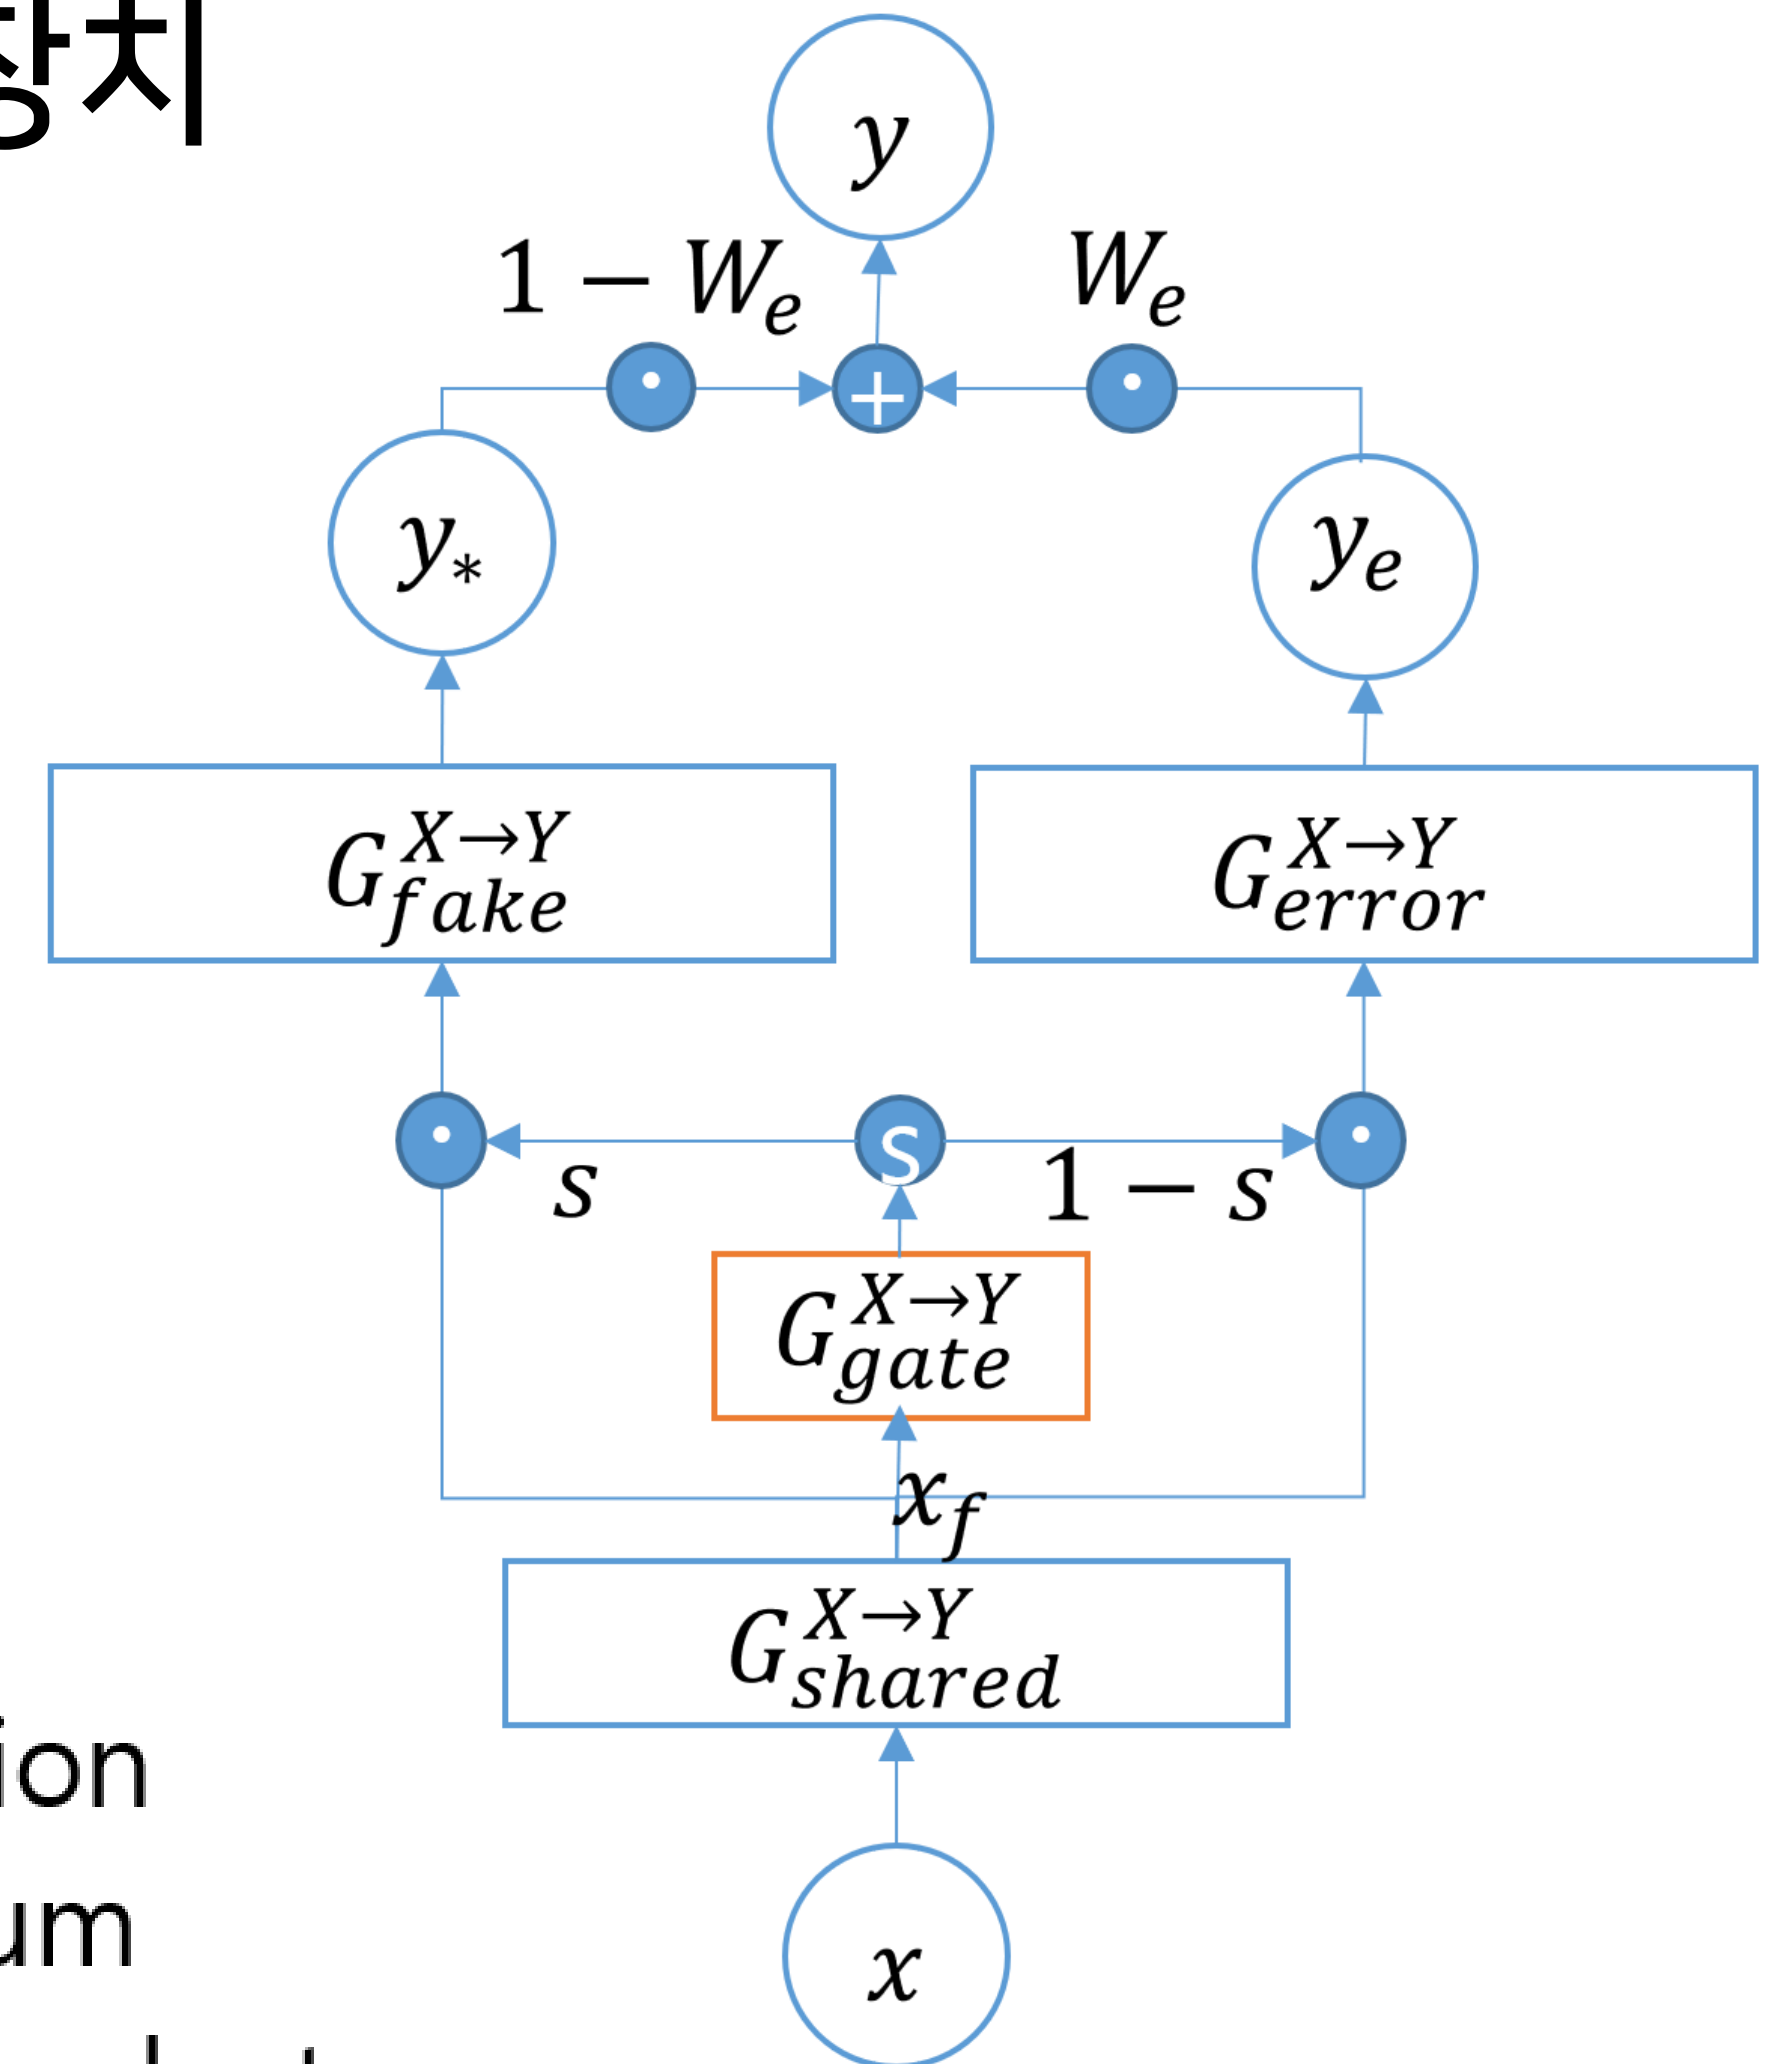


3.5 GET-GAN with feature gate

오류를 유발하는 특징을 명확히 분해하기 위한 장치

- $G_{shared}^{X \rightarrow Y}$ 와 두 브랜치 사이에 feature gate를 삽입
- Feature gate가 필요한 특징을 선택하도록 gradient weight가 가이드 함
- Feature gate는 두 브랜치에 전달할 특징을 선택하도록 가중치를 출력
 - . 에러에 해당하는 특징 : 0에 가까운 값을 출력
 - . 에러가 아닌 특징 : 1에 가까운 값을 출력
- $G_{fake}^{X \rightarrow Y}$ 는 $s x_f$ 를 입력으로 받음
- $G_{error}^{X \rightarrow Y}$ 는 $(1 - s) x_f$ 를 입력으로 받음

- Ⓢ : sigmoid activation
- ⊕ : element-wise sum
- ⦿ : element-wise product




3.6 다른 이미지 변환 기술과 비교

기존 기술에 비해 가려짐과 왜곡이 심한 입체 초음파 이미지를 잘 처리함

입체 초음파



CycleGAN



U-GAT-IT



Babyface 1.0
GET-GAN



오늘 살펴본 내용

Babyface 4.0



4. 앞으로 풀어야 할 문제들


4.1 attribute mismatch 문제

두 도메인의 특정 속성이 서로 다른 분포를 갖는 경우

- 대부분의 dataset은 unpaired dataset
- 변환하고자 하는 타겟 속성 외에 두 도메인에서 분포가 서로 다른 속성이 존재

Paired dataset

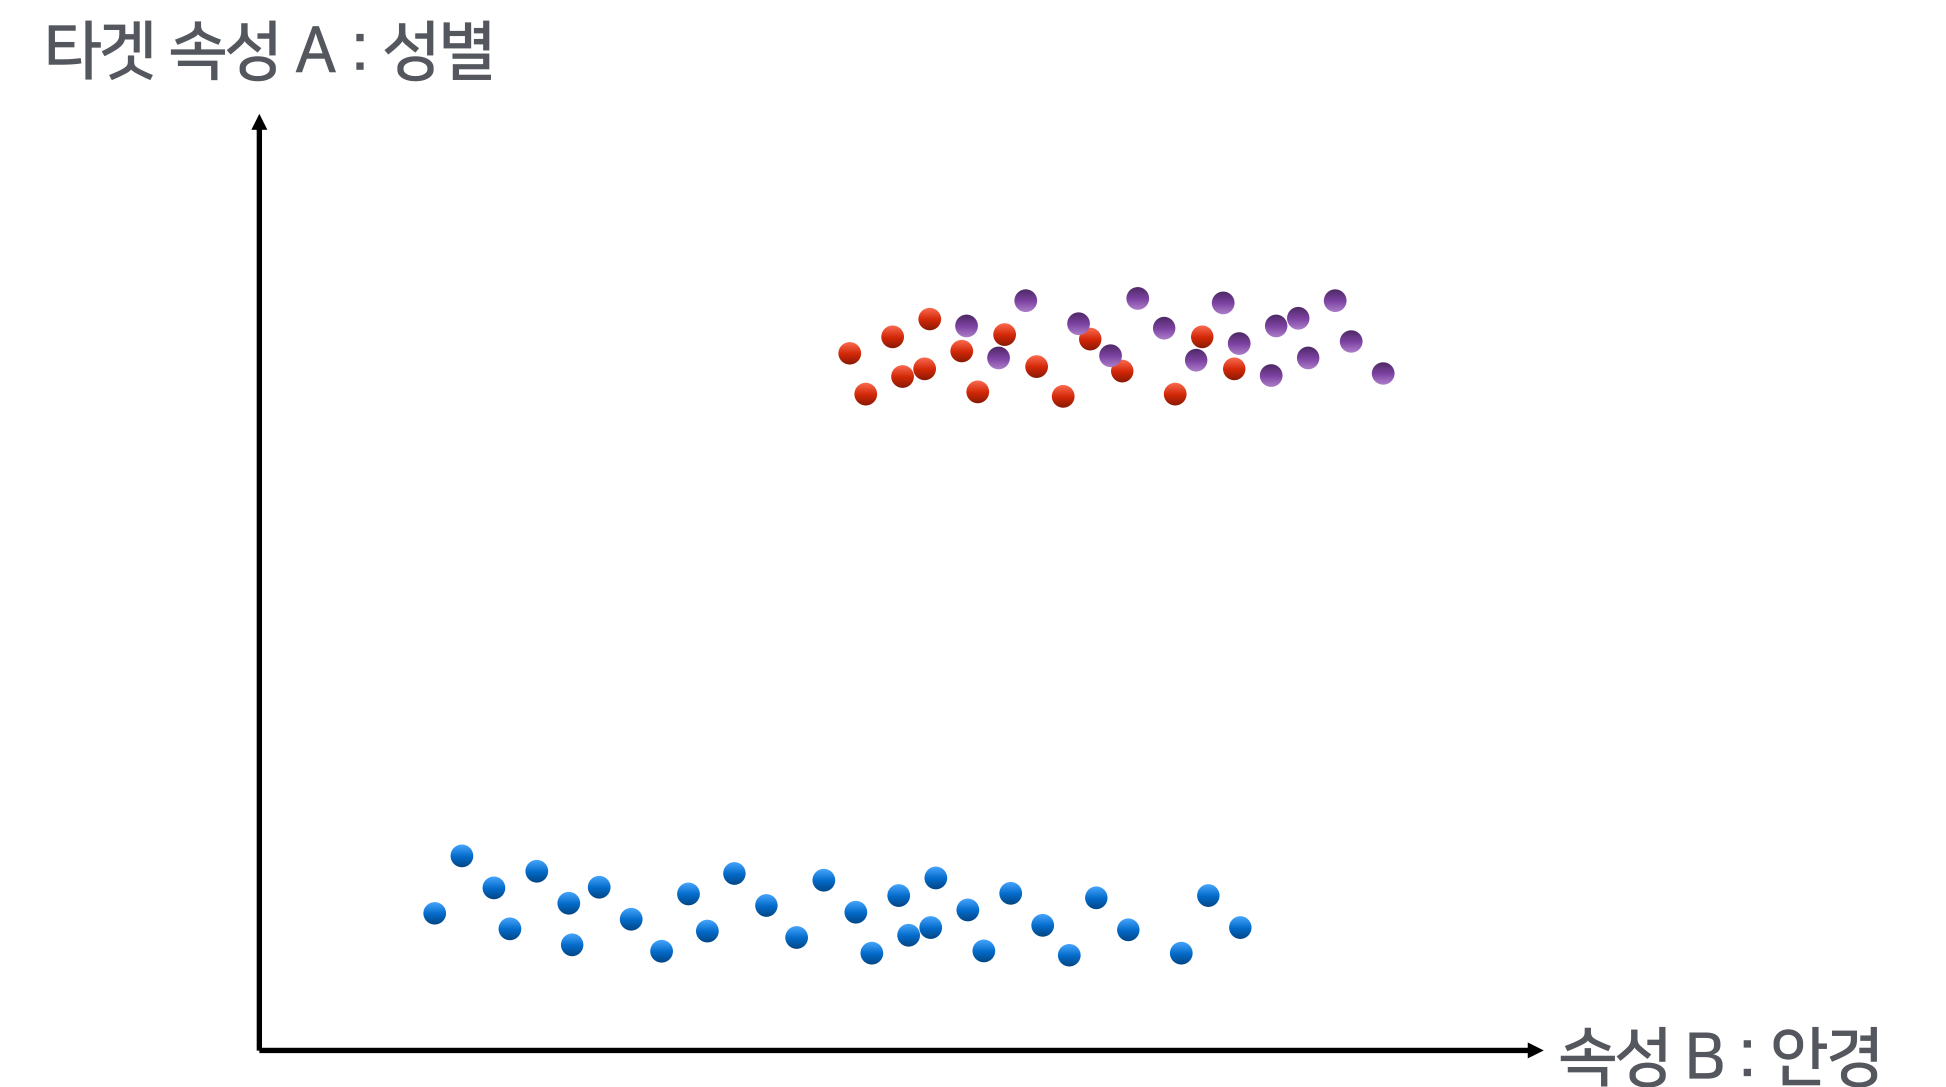
Ideal conversion : 타겟 속성만 변환



● 소스 도메인 ● 타겟 도메인 ● 변환된 이미지

Unpaired dataset

Mismatched conversion : 다른 속성도 변경됨



● 소스 도메인 ● 타겟 도메인 ● 변환된 이미지

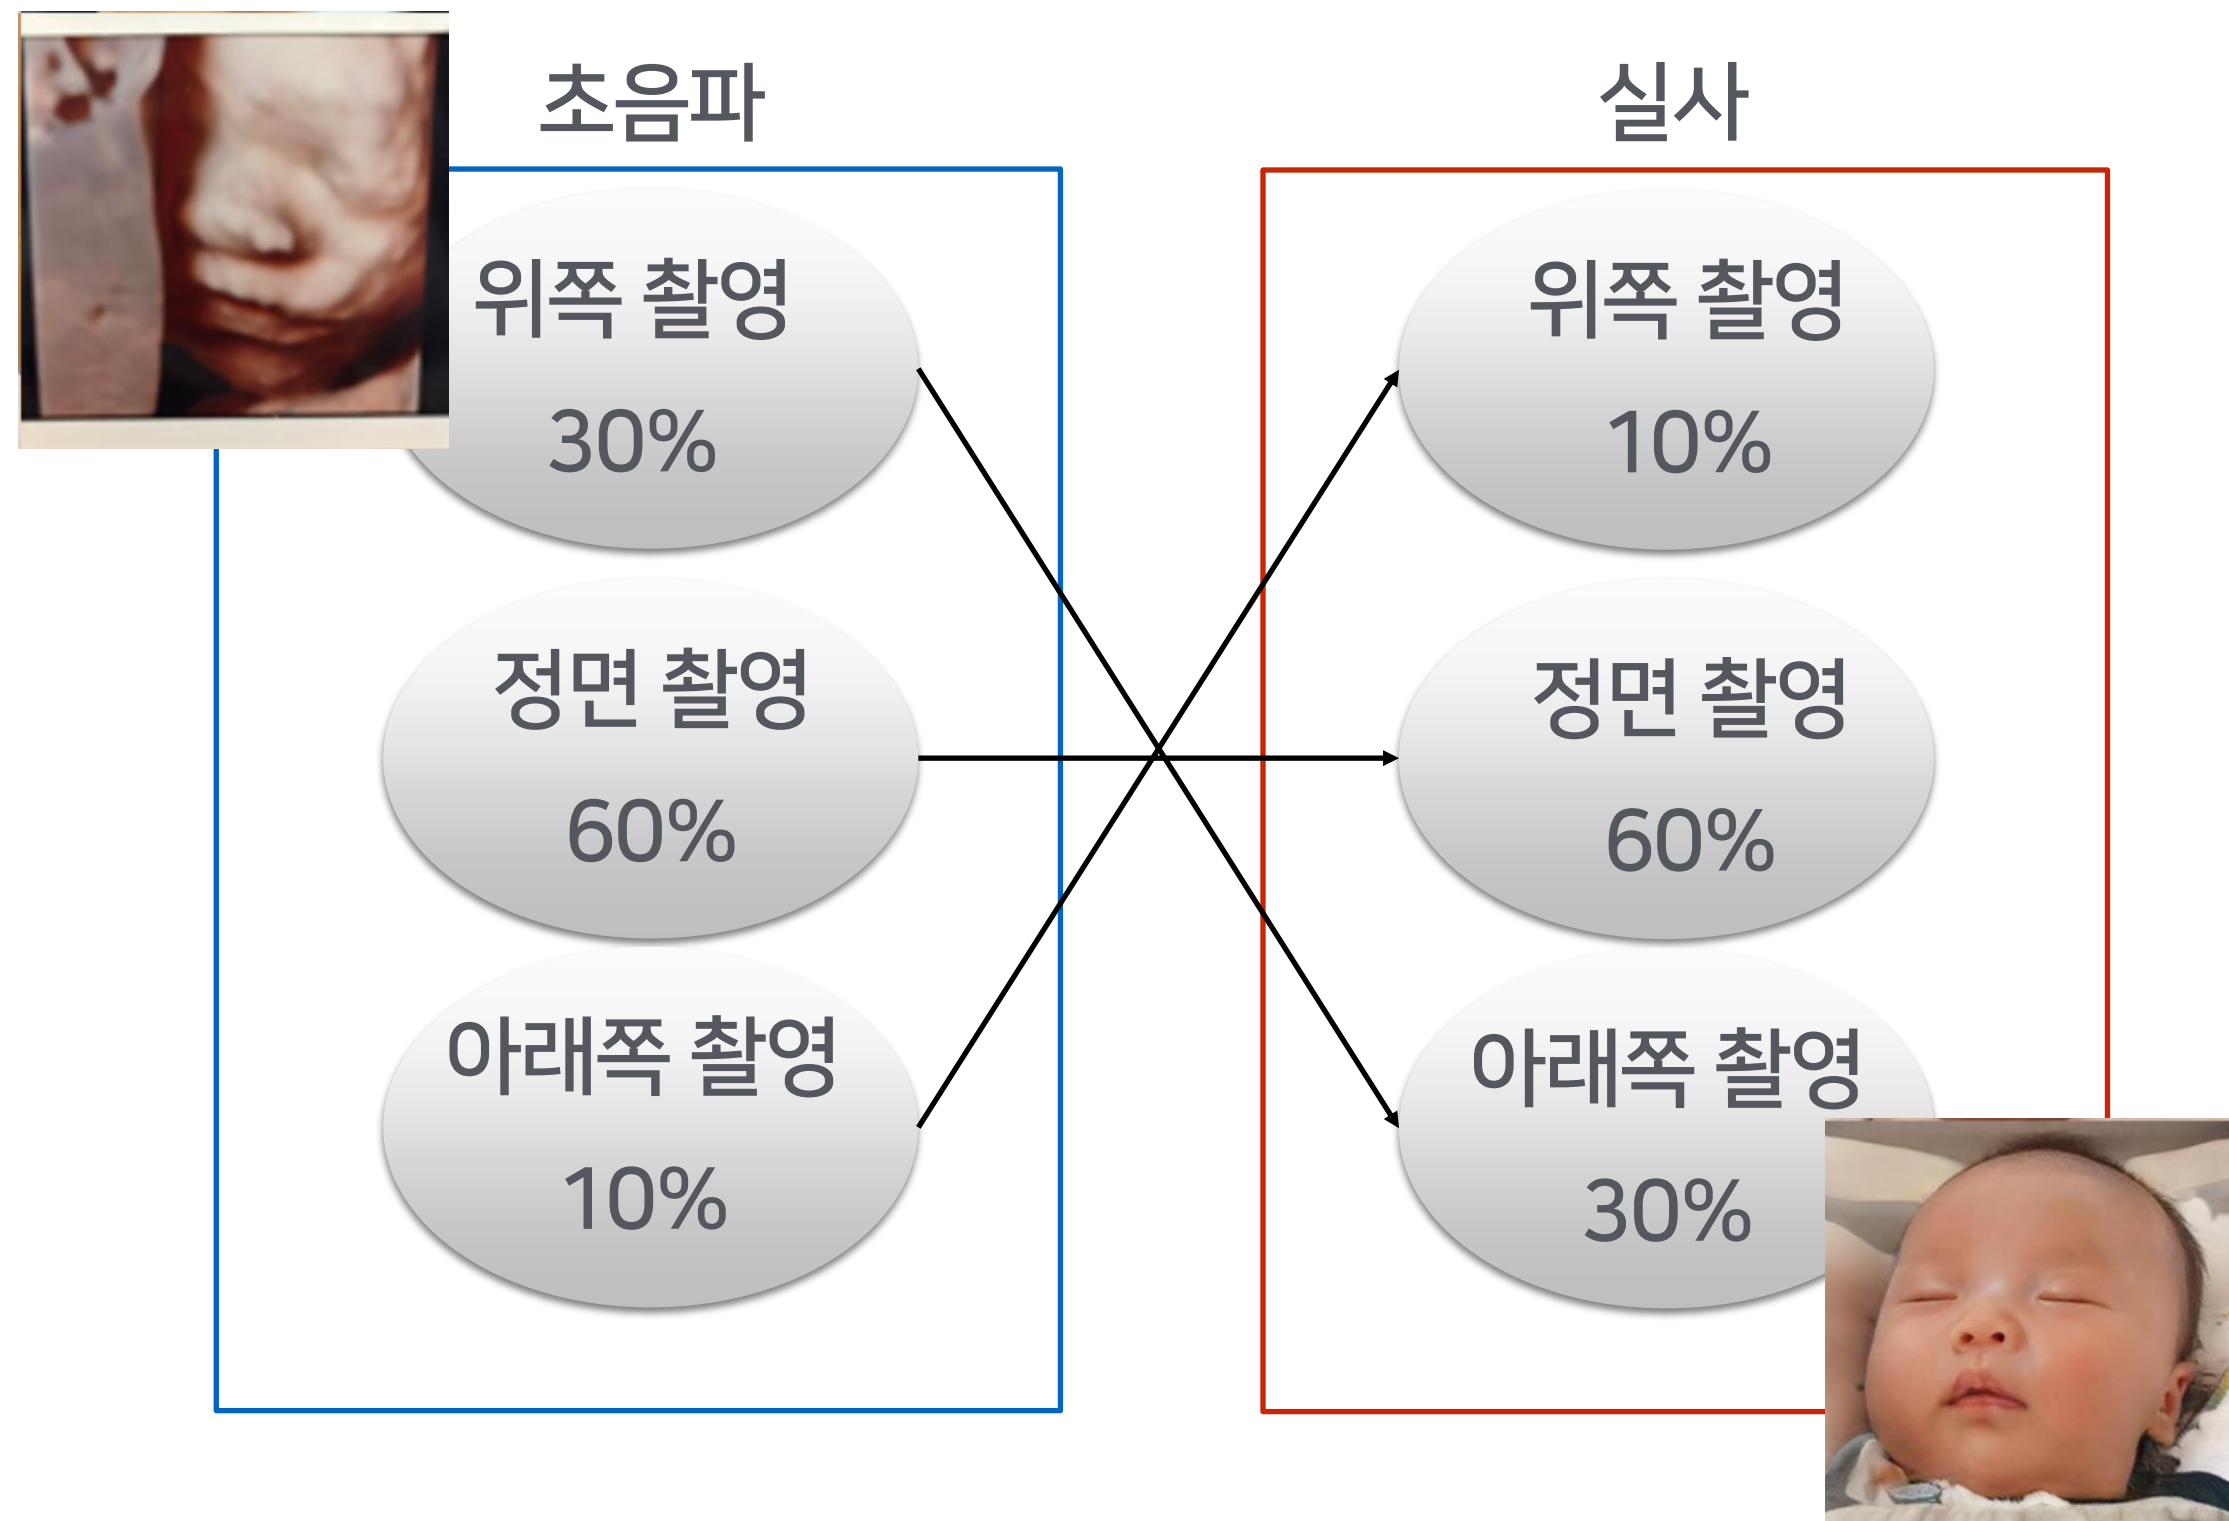
4.2 attribute mismatch의 예

두 도메인의 특정 속성이 서로 다른 분포를 갖는 경우

Babyface

두 도메인에서 얼굴 구도의 분포가 서로 다름

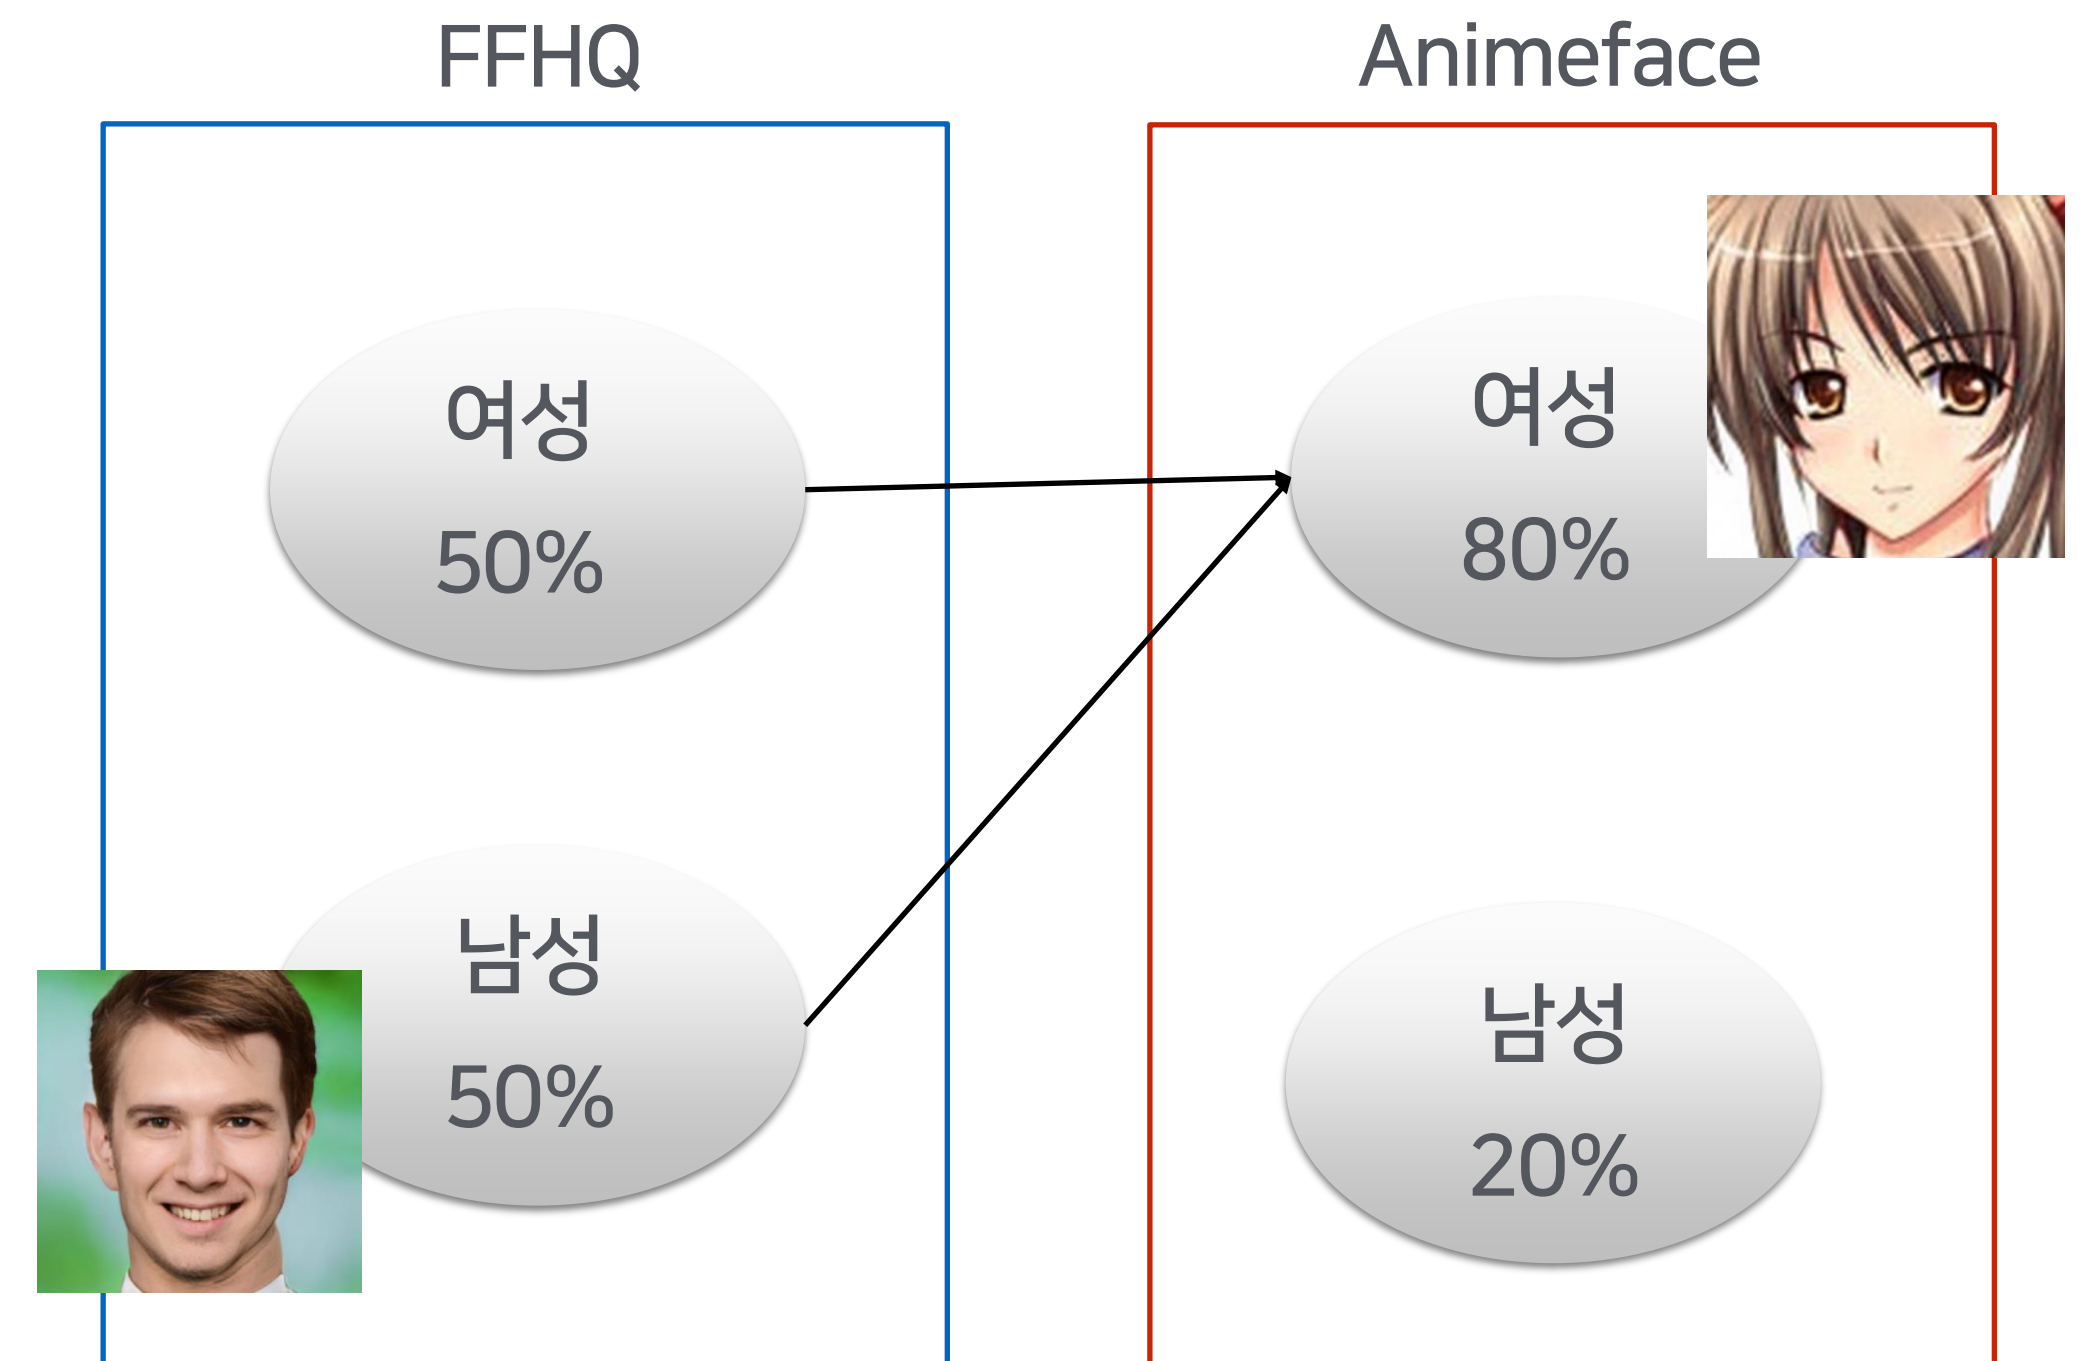
→ 얼굴 구도가 잘못 맵핑 됨



Animeface

두 도메인에서 남녀 성비가 다름

→ Texture 뿐만 아니라 성별까지 변환됨

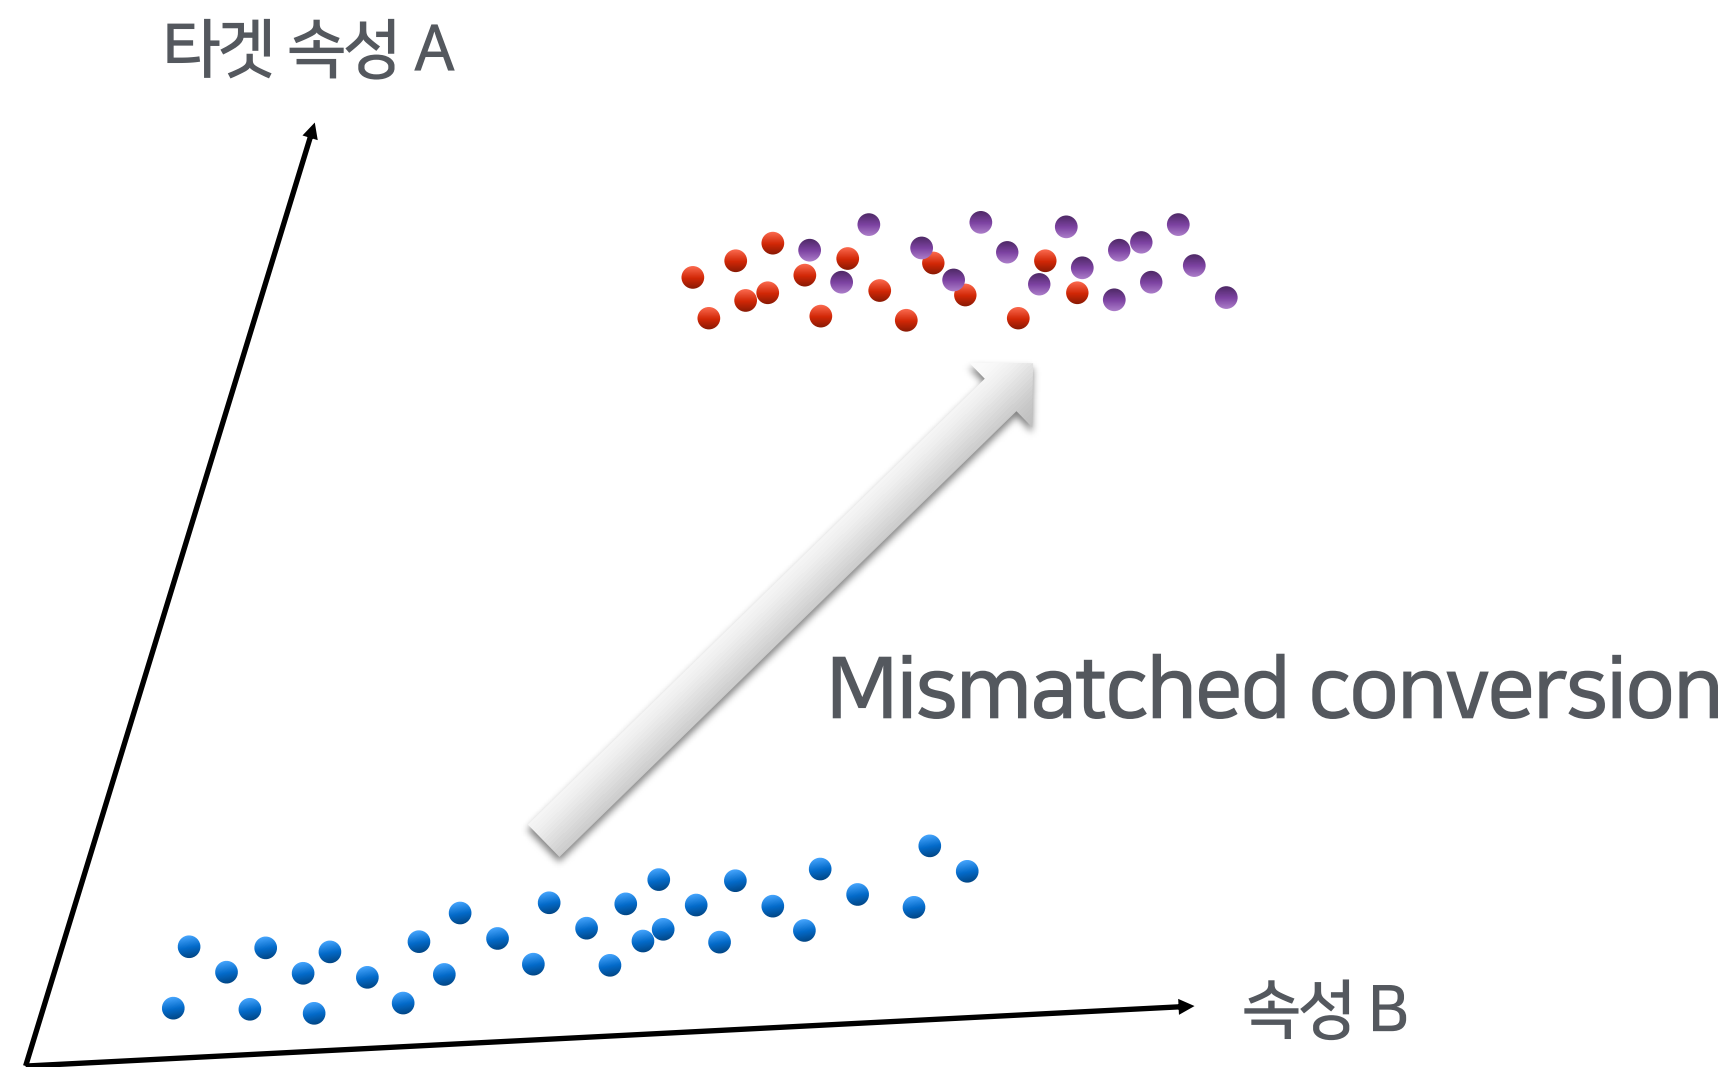


4.3 attribute mismatch를 해결하려면?

각 속성이 disentangled 된 representation이 필요함


- unpaired dataset에서 ideal conversion을 수행할 수 있음
- 여러 도메인 간에 공유되는 속성을 재활용할 수 있어 적은 데이터로 학습 가능

Entangled representation



● 소스 도메인 ● 타겟 도메인 ● 변환된 이미지


Disentangled representation





● 소스 도메인 ● 타겟 도메인 ● 변환된 이미지



Q & A





Thank You

