

# An Edge Detection Technique for Performance Improvement of eGAN

Lee Cho Youn<sup>†</sup> · Ji Su Park<sup>††</sup> · Jin Gon Shon<sup>†††</sup>

## ABSTRACT

GAN(Generative Adversarial Network) is an image generation model, which is composed of a generator network and a discriminator network, and generates an image similar to a real image. Since the image generated by the GAN should be similar to the actual image, a loss function is used to minimize the loss error of the generated image. However, there is a problem that the loss function of GAN degrades the quality of the image by making the learning to generate the image unstable. To solve this problem, this paper analyzes GAN-related studies and proposes an edge GAN(eGAN) using edge detection. As a result of the experiment, the eGAN model has improved performance over the existing GAN model.

Keywords : Generative Adversarial Network, Loss Function, Edge Detection, eGAN

## eGAN 모델의 성능개선을 위한 에지 검출 기법

이 초 연<sup>†</sup> · 박 지 수<sup>††</sup> · 손 진 곤<sup>†††</sup>

## 요 약

GAN(Generative Adversarial Network, 생성적 적대 신경망)은 이미지 생성모델로서 생성기 네트워크와 판별기 네트워크로 구성되며 실제 같은 이미지를 생성한다. GAN에 의해 생성된 이미지는 실제 이미지와 유사해야 하므로 생성된 이미지와 실제 이미지의 손실 오차를 최소화하는 손실함수(loss function)를 사용한다. 그러나 GAN의 손실함수는 이미지를 생성하는 학습을 불안정하게 만들어 이미지의 품질을 떨어뜨린다는 문제점이 있다. 이러한 문제를 해결하기 위해 본 논문에서는 GAN 관련 연구를 분석하고 에지 검출(edge detection)을 이용한 eGAN(edge GAN)을 제안한다. 실험 결과 eGAN 모델이 기존의 GAN 모델보다 성능이 개선되었다.

키워드 : 생성적 적대 신경망, 손실 함수, 에지 검출, eGAN

## 1. 서 론

인공지능에 관하여 관심이 커지면서 산업 전반으로 딥러닝 모델에 관한 연구가 활발하게 진행되고 있다. 모델 중에서 GAN은 확률 계산을 근사화하는 어려움을 해결하기 위해서 생성모델을 훈련하는 프레임워크로 도입되었다. GAN은 시그모이드 크로스 엔트로피 손실함수(sigmoid cross entropy loss function)를 사용하기 때문에 학습이 불안정하고 그라디언트(vanishing gradient)가 사라진다. 손실함수에서 최소화과 최대화의 경쟁 과정에서 이론적 가정이 깨지면서 불안정한 결과가 출력된다[1]. 손실함수는 회귀 문제에 평균제곱오차를 사용하고 분류 문제에는 크로스 엔트로피 오차 등

을 사용한다. 또한, 기존 이미지 생성 학습 과정에서 사용되는 평균제곱오차 손실함수는 예측한 값에 대한 정확성을 추정하는 방법을 사용하였으며, 픽셀 별로 모든 가능한 해(feasible solution)의 평균값을 추정하기 때문에 이미지가 선명하지 못하고 흐려지는 경향이 있다. GAN은 개별 속성을 유지하며 최대한 학습 데이터의 매니폴드(manifold)에 가까워지도록 훈련한다[1].

GAN은 생성기 네트워크와 판별기 네트워크를 사용하여 최소화대화 2인 경쟁게임으로 진짜 같은 이미지를 생성한다. 생성 이미지와 실제 이미지와의 오차를 최소화하기 위한 손실함수는 모델 성능의 최적화를 위하여 필요하다[2].

본 논문은 GAN 계열 신경망에서 모델별로 개선된 손실함수들을 분류하고 특징을 분석한다. 분석한 결과 에지검출을 기반으로 개선된 손실함수를 적용한 edge GAN을 제안한다. 본 논문의 구성은 다음과 같다. 제2장에서는 본 논문에서 제안하는 eGAN의 관련 연구로 GAN에서 손실함수의 분석 그리고 에지 검출을 알아본다. 제3장에서는 본 논문에서 제안

\* 이 논문은 한국방송통신대학교 학술연구비 지원을 받아 작성된 것임.  
† 준 회원: 한국방송통신대학원 정보과학과 석사  
†† 정 회원: 전주대학교 컴퓨터공학과 교수  
††† 중신회원: 한국방송통신대학원 컴퓨터공학과 교수  
Manuscript Received: December 23, 2020  
Accepted: January 13, 2021  
\* Corresponding Author: Jin Gon Shon(jgshon@knu.ac.kr)

하는 에지 검출에 기반한 GAN 모델의 손실함수와 작업처리에 관하여 기술한다. 제4장에서는 제안하는 eGAN의 손실함수 성능을 알아보기 위해 기존 GAN과 비교하여 성능을 측정하고 평가한다. 제5장에서는 본 논문에서 eGAN 모델이 기존의 GAN 모델보다 개선된 장점에 관하여 기술하고 연구의 한계점과 향후 연구방향에 대하여 기술한다.

## 2. 관련 연구

### 2.1 손실함수

손실함수는 신경망에서 학습하여 얻은 예측 값( $y$ )과 정답 레이블( $t$ )과의 오차를 나타내는 함수를 나타낸다. 예측 값은  $y = wx + b$ 이며  $w$ 는 가중치,  $b$ 는 편향이다. 손실함수의 값을 최소화하기 위해서 최적화된 매개변수  $w$ 와  $b$ 를 구해야 하며 경사 하강법(gradient descent)을 사용한다. 손실함수 식은 Equation (1), (2)와 같다.

$$E = \frac{1}{2} \sum (y_k - t_k)^2 \tag{1}$$

$$E = - \sum t_k \log y_k \tag{2}$$

Equation (1)은 평균제곱오차(mean squared error)이며 Equation (2)는 크로스 엔트로피 오차이다.  $k$ 는 데이터의 차원 수이며, 예측 값( $y$ )과 정답 레이블( $t$ )과의 오차를 계산하고 마이너스를 피하기 위해 제공하고 그 합을 더한다. Equation (2)는 확률 로그함수를 사용하며  $\log$ 는 밑이  $e$  인 자연로그이며,  $t$ 에서 1에 해당하는 확률  $y$  값을 대입하여 크로스 엔트로피 오차를 계산한다.

### 2.2 GAN

GAN은 적대적 과정을 통해 생성모델을 평가하기 위한 프레임워크이다[2]. GAN의 손실함수 식은 Equation (3)과 같다.

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \tag{3}$$

Equation (3)에서 GAN의 목적은 랜덤 데이터  $p_z(z)$ 를 실제 데이터  $p_{data}(x)$ 의 분포와 유사하게 만드는 것이다. 균일 분포  $[-1, 1]$ 로부터 샘플링된  $z$  벡터를 이용하여 이미지를 생성한다.  $V$ 는 가치함수,  $D$ 는 판별기,  $G$ 는 생성기,  $E$ 는 기댓값,  $x$ 는 실제 데이터의 샘플 이미지,  $D(x)$ 는 실제 이미지로 판단할 확률,  $G(z)$ 는 생성기에서 얻은 샘플 이미지,  $D(G(z))$ 는 생성된 이미지로 판단할 확률이다.

$\log(1 - D(G(z)))$ 를 최소화한다. 따라서 생성기 입장에서는 판별기가 실제라고 판단할 수 있도록 최소의 손실함수 값이어야 한다. 손실함수의 전역 최소값을 찾기 위해 연속적인 그라디언트를 사용한다. GAN은 시그모이드 크로스 엔트로피

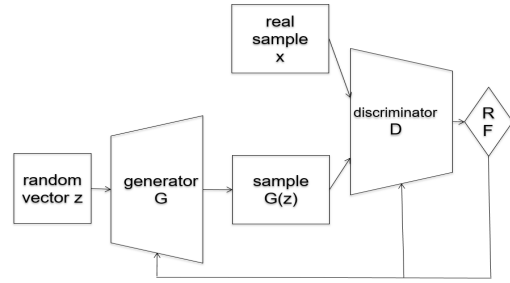


Fig. 1. GAN Model Structure

손실함수를 사용하여 학습이 불안정하고 이미지 품질이 떨어지는 단점이 있다. 시그모이드는 활성화 함수이며 0에서 1 사이의 확률값을 출력한다[2]. GAN 모델은 기본적으로 생성기  $G$ 와 판별기  $D$ 를 동시에 훈련시킨다. GAN의 구조는 Fig. 1과 같다.

Fig. 1에서 알 수 있듯이 GAN 모델은 주요 구성요소로서 생성기 네트워크  $G$ 와 판별기 네트워크  $D$ 가 있다.

랜덤 벡터  $z$ 는 잠재적 공간에서 무작위로 선택되는 데이터이다. 생성기  $G$ 는 랜덤 벡터  $z$ 를 입력받고 가짜 데이터  $G(z)$ 를 생성한다. 판별기  $D$ 는 실제 데이터  $x$ 와 가짜 데이터  $G(z)$ 를 입력으로 받고, 생성된 이미지가 진짜인지 가짜인지 판별하여 분류한다. GAN 모델은 신경망의 학습을 통해 생성기  $G$ 의 분포가 최대한 실제 데이터 분포와 유사해지도록 하는 것이다[3-7].

### 2.3 WGAN과 WGAN-GP

WGAN(Wasserstein GAN)은 Earth-Mover(EM) 거리의 근사를 최소화하는 방법을 이용하여 wasserstein 거리의 최대 하한(inf)을 적용한 모델이다. WGAN의 기댓값은 예측값과 실제값 차이의 norm(이동거리)이 최솟값이 되어야 한다. 모든 결합분포의 집합, 실제 데이터 분포  $P_r$ 를 생성기의 분포  $P_g$ 로 변환하기 위해  $x$ 에서  $y$ 로 이동되어야 하는 매스의 양을 나타낸다[8].

WGAN-GP에서 가중치 클리핑은 그라디언트의 길이를 조정하는 하면서 샘플을 생성할 때 오작동을 한다. 이때 그라디언트가 사라지거나 폭발하기 때문에 대안으로 비평가에서 그라디언트의 norm에 페널티(penalty)를 적용한다. 어디서나 1 이하의 norm을 가진 그라디언트가 있는 경우에만 비평가 결과의 그라디언트 norm을 입력에 직접적으로 제한하는 것을 고려하여 1에서 멀어지면 페널티  $\lambda$ 를 적용한다. WGAN-GP의 손실함수는 Equation (4)와 같다.

$$L = \int_{x \sim P_g} D(x) - \int_{x \sim P_r} D(x) + \lambda \int_{x \sim P_x} E [(\|\nabla_x D(\hat{x})\|_2 - 1)^2] \tag{4}$$

Equation (4)는 판별기( $D$ )의 목적 함수에 페널티를 추가,

Table 1. Loss Function Comparison Analysis in GAN Model

	Characteristic	Advantages	Disadvantages
GAN	<ul style="list-style-type: none"> <li>• Use of cross entropy loss function</li> <li>• Using the sigmoid activation function</li> </ul>	<ul style="list-style-type: none"> <li>• Not overfitting</li> <li>• No Markov chain required</li> </ul>	<ul style="list-style-type: none"> <li>• Learning insecurity</li> <li>• It falls into the local minimum</li> <li>• vanishing gradients</li> </ul>
CGAN	<ul style="list-style-type: none"> <li>• Use desired conditions <math>y</math> for generator(G) and discriminator(D)</li> </ul>	<ul style="list-style-type: none"> <li>• Data generated can be adjusted</li> </ul>	<ul style="list-style-type: none"> <li>• Reimplemented from D to MLP</li> <li>• Overfit</li> <li>• Needs further exploration of hyperparameter space and architecture</li> </ul>
WGAN	<ul style="list-style-type: none"> <li>• Using the moving amount of EM distance</li> <li>• Use the smallest boundary value inf(lowest maximum) of the subset in real numbers</li> <li>• Discriminator(D) is called critic</li> </ul>	<ul style="list-style-type: none"> <li>• Better learning stability than GAN</li> <li>• Gradient loss reduction</li> <li>• No need to maintain balance between generator(G) and discriminator(D)</li> </ul>	<ul style="list-style-type: none"> <li>• High learning speed makes learning unstable</li> <li>• Sample generation malfunction due to weight clipping</li> </ul>
WGAN-GP	<ul style="list-style-type: none"> <li>• Penalty applied to gradients in criticism loss</li> </ul>	<ul style="list-style-type: none"> <li>• Improved learning speed compared to WGAN</li> <li>• Sample quality improvement</li> <li>• Resolve weighted clipping as a penalty</li> </ul>	<ul style="list-style-type: none"> <li>• Overfit in critics</li> </ul>
EBGAN	<ul style="list-style-type: none"> <li>• See the discriminator(D) as an energy function</li> <li>• Auto encoder applied</li> </ul>	<ul style="list-style-type: none"> <li>• Improved learning stability compared to GAN</li> <li>• High resolution image creation</li> </ul>	<ul style="list-style-type: none"> <li>• Difficult to optimize the discriminator(D)</li> <li>• Mode collapse due to incomplete gradient</li> </ul>
BEGAN	<ul style="list-style-type: none"> <li>• Auto encoder applied to the discriminator(D)</li> </ul>	<ul style="list-style-type: none"> <li>• Improving learning stability</li> <li>• Maintain balance between generator(G) and discriminator(D)</li> </ul>	<ul style="list-style-type: none"> <li>• Loss of compressed data due to auto-encoder</li> </ul>
LSGAN	<ul style="list-style-type: none"> <li>• Use of least squares loss function in the discriminator(D)</li> <li>• Penalty applied to fake samples</li> </ul>	<ul style="list-style-type: none"> <li>• Improved learning stability compared to GAN</li> <li>• High resolution image creation</li> </ul>	<ul style="list-style-type: none"> <li>• JS distance cannot effectively measure the distance of all distributions</li> <li>• Overfit</li> </ul>

1에서 멀어지면 페널티  $\lambda$ 를 적용한다. 랜덤샘플  $\hat{x} \sim P_x$ 에 대한 그라디언트 놈에 페널티가 있는 제약 조건이다[9]. 그 외 CGAN, EBGAN, BEGAN, LSGAN의 손실함수 비교분석은 Table 1과 같다.

#### 2.4 에지 검출

GAN에서 사용하는 시그모이드 크로스 엔트로피 손실함수는 평균제곱오차 손실함수를 사용하는 것보다 이미지 품질이 향상된다. 그러나 GAN은 손실에 대한 최소최대화 문제 때문에 이미지를 생성하는 학습이 불안정하며, 시그모이드 함수는 그라디언트가 사라지거나 폭발하기 때문에 이미지 품질이 떨어진다. 이러한 문제를 해결하기 위하여 기존의 GAN에서 사용하는 손실함수보다 개선된 GAN의 손실함수에 관한 연구가 필요하다. GAN에서는 생성기 네트워크와 판별기 네트워크를 이용하고 여기에 이미지 인식이나 분류에 사용하는 CNN의 구조를 적용하여 생성기와 판별기를 conv net으로 응용한다.

영상 처리에서 에지는 이미지 인식이나 분류에 사용할 수 있다. 이미지에서 이웃하는 픽셀값의 차이가 크고 연속적이면 에지를 구별할 수 있다. 에지 검출에는 prewitt, roberts, sobel을 이용한 에지 검출과 canny 에지 검출을 적용할 수 있다. sobel은 중심 차분 필터에 수직 방향으로 스무딩 필터

를 적용하며 스무딩 필터는 [1,2,1] 형태로 가운데 화소에 더 많은 비중을 두고 있다.

canny 에지 검출은 에지의 위치에 대하여 이미지에 있는 실제 에지와 검출한 에지 사이의 거리는 반드시 최소가 되어야 한다. 이러한 특징을 이용하여 에지 검출을 이용한 개선된 손실함수를 적용한 eGAN을 제안한다. 오차를 줄이기 위한 손실함수를 분석한 결과 이미지의 경계를 추출하여 생성된 경계와 실제 경계와의 손실함수를 구할 필요가 있다.

에지 검출기는 다음과 같이 성능과 관련된 공통 기준이 있다.

- 낮은 오류율이다. 이미지에서 발생하는 가장자리를 놓치지 말아야 하며 가짜 응답이 없어야 한다.
- 에지 포인트가 잘 현지화되어 있다. 즉, 검출기가 표시한 지점과 실제 에지의 중심 사이의 거리를 최소화해야 한다. 이것은 왼쪽과 오른쪽 이미지 사이 또는 약간 다른 시간에 생성된 이미지 사이에서 작은 시차가 측정되는 모션의 모양에 특히 적용된다.
- 단일 에지에 대한 하나의 응답으로 동일한 에지에 대해 두 개의 응답이 있을 때 그중에서 하나는 거짓으로 판단되어야 한다. 에지의 도함수는 픽셀값이 일정한 부분에서는 0이 되고, 픽셀값이 차이가 있는 부분에서는 0이 되지 않는다. 이미지는 픽셀값으로 표현되므로 픽셀값의 차이를 이용하여 에지를 구할 수 있다[11].

### 3. 에지 검출 기법

#### 3.1 손실함수 감소

eGAN 모델은 기본적으로 GAN의 변형 모델로서, 제2장의 관련 연구에서 설명한 기존의 GAN 모델별 손실함수의 특성과 장단점의 분석을 기반으로 에지 검출 단계를 추가한 모델이다.

GAN 모델의 손실함수를 비교 분석한 결과 판별기에 조건부 적용, 최대 하한 적용, 오토 인코더, 패널티 등 손실함수의 개선된 방법이 적용되었다. 손실함수의 오차를 줄이기 위한 조건은 다음과 같다. 판별기는 기존 GAN보다 더 정확해야 한다. 따라서 실제 에지와 검출한 에지 사이의 거리는 반드시 최소가 되어야 하는 에지 검출이 필요하다. 생성기와 판별기는 업데이트 균형이 맞아야 한다. 판별기는 실제 이미지와 생성된 이미지를 평가 비교만 한다. 학습 속도가 빠르면 모드 붕괴가 되기 때문에 학습률을 조절해야 한다.

#### 3.2 에지 검출 단계

에지는 경계선이나 윤곽선으로 이미지 안에 있는 객체의 경계를 가리키며, 이미지에서 물체의 크기를 측정하거나 배경에서 물체를 분리, 인식 또는 분류하기 위해서 사용된다. 이미지에서 에지를 검출하기 위해서는 수직 에지와 수평 에지를 찾아야 한다. 에지 검출은 가우시안 필터를 적용하는 가우시안의 도함수이다. 1차원 가우시안 도함수는 Equation (5)와 같다[11].

$$f'(x) = -\frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (5)$$

Equation (5)에서  $x$ 는 이미지,  $f(x) = \exp\left(-\frac{x^2}{2\sigma^2}\right)$ 는 가우시안 필터,  $\sigma$ 는 표준편차를 나타내며  $\sigma$ 의 값이 크면 평탄한 곡선이 되고, 값이 작으면 뾰족한 곡선이 된다. 필터는 잡음을 스무딩하고 가능한 에지 후보 픽셀들을 찾는다. 필터는 열 필터로 열에 적용하고, 행 필터로 행에 적용한다. 에지 검출에 대한 과정을 4단계로 정리하면 다음과 같다.

- 1단계: 가우시안 필터를 이용한 노이즈 제거
- 2단계: 기울기 값이 높은 부분 찾기
- 3단계: 최댓값이 아닌 픽셀의 값을 0으로 만들기
- 4단계: 히스테리시스(hysteresis) 임계값 처리

임계값은 실제 에지인지 아닌지 판단한다. 임계값은 낮은 값(L)과 높은 값(H)을 가지며 높은 값보다 큰 값을 가진 픽셀은 에지이다.

#### 3.3 eGAN

eGAN은 GAN을 기반으로 하며 판별기에서 생성된 이미지와 실제 이미지를 판별할 때 이미지에 있는 실제 에지와 검

출한 에지 사이의 거리는 반드시 최소가 되어야 한다고 정의한 에지 검출을 적용하여 생성된 이미지와 실제 이미지와의 차이를 최소화한다. eGAN의 목표는 GAN에서 에지 검출 성질을 이용하여 생성된 데이터와 실제 데이터의 차이 값이 0에 근사한 값이 되도록 하는 것이다. eGAN은 에지 검출을 이용하기 때문에 분포 거리를 효과적으로 측정한다. 제안하는 eGAN에서 사용하는 손실함수는 Equation (6)과 같다.

$$\min_{G, D} \max_D V(D, G) = [E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] + \lambda E_{x \sim p_{data}} [(\|\nabla D(x)\|_2 - 1)^2] \quad (6)$$

Equation (6)은 GAN의 판별기  $D$ 에 그라디언트의 이동 거리에 에지  $e$ 와 1에서 멀어지면 그라디언트 패널티  $\lambda$ 를 적용한다.  $L2\text{-norm}(\|\cdot\|_2)$ 은 그라디언트의 방향을 계산한다.

접선에 의한 에지 기울기의 오차를 최소화하기 위해서 연속적인 도함수를 미분으로 표현하면 Equation (7), (8)과 같다.

$$f'(x) = f(x+h) - f(x-h) \quad (7)$$

$$\frac{df(x)}{dx} = \lim_{h \rightarrow 0} \frac{f(x+h) - f(x-h)}{2h} \quad (8)$$

Equation (7), (8)에서  $h$ 는 미분을 위한 0에 가까운 작은 값이며 에지 기울기의 크기를 구할 수 있다.


## 4. 실험

실험의 목적은 GAN 모델과 eGAN 모델을 실험하여 GAN 모델의 손실 값과 eGAN 모델의 손실 값을 비교하는 것이다. 만일 eGAN 모델의 손실 값이 GAN 모델의 손실 값보다 작게 나온다면 eGAN 모델이 그만큼 성능이 개선된 것이다. 따라서 동일한 이미지 데이터 세트에 대해 GAN 모델과 eGAN 모델을 적용하여 각 모델의 손실 값을 비교한다. 에지 검출 단계 4단계를 적용하면 에지를 적용한 에지 검출 임계값을 각각 다르게 적용할 수 있다.


본 논문의 GAN과 eGAN 모델 실험에서는 에지 검출 임계값을  $L=60$ ,  $H=240$ 으로 설정하였다. 에지를 구하기 위해서는 높은 임계값(H)보다 큰 값인 픽셀은 모두 에지이다.  $H=240$ 은 단순한 이미지를 실험했을 때  $H=240$ 이 적절하였다. 같은 조건으로 낮은 임계값  $L=10$ 이면 의미 있는 에지가 검출된다. 그러나 불필요한 잡음까지 검출되었다.  $L$ 값이 높으면 에지의 연결이 불안정하다.  $L=60$ 일 때 이미지가 선명하게 출력되었다.

GAN 모델과 eGAN 모델의 생성된 이미지를 비교한 결과는 Fig. 2와 같다.

Fig. 2(A)는 GAN 모델의 생성된 이미지, Fig. 2(B)는 eGAN



(A) Generated Image Result of GAN Model



(B) Generated Image Result of eGAN Model

Fig. 2. Comparison of GAN and eGAN Generated Image Results

Table 2. Performance Comparison of GAN and eGAN

model	learning rate	edge	penalty	D_loss
GAN	0.0002	×	×	0.7045
eGAN	0.0002	○	0.1	0.8479
	0.0002	○	0.2	0.5094
	0.0002	○	0.3	0.4253

모델의 생성된 이미지이다. a는 랜덤 노이즈로 생성된 이미지이다. Fig. 2(B)를 보면 eGAN 모델이 GAN 모델보다 생성된 이미지가 빠르고 선명하게 보인다.

GAN 모델과 eGAN 모델의 성능 비교는 Table 2와 같다.

Table 2에서 GAN 모델에 에지와 패널티 0.1를 적용한 eGAN 모델은 GAN보다 성능이 14% 향상되었다. 에지의 임계값을 다양하게 적용해 볼 필요가 있다.

### 5. 결 론

본 논문은 GAN 모델의 이미지 처리에서 손실함수의 필요성을 설명하고, GAN 모델에서 사용하는 손실함수에 대하여 개선된 방법별로 분류하고 특징을 분석하였다. 손실함수를 비교 분석한 결과 모든 판별기에 손실함수의 개선된 방법이 적용되었다.

에지 검출은 에지 후보를 정확하게 찾기 위해서는 미분을 이용한 그라디언트의 방향과 크기를 구해야 한다. 그리고 임계값을 낮은 값(L)과 높은 값(H)을 적용하여 에지를 검출한다.

실험 결과에서 GAN에 에지 검출을 적용한 eGAN은 GAN과 비교했을 때 판별기 손실은 14%의 차이로 손실이 감소하였다. 따라서 eGAN 모델이 GAN 모델보다 성능이 개선되었다.

본 논문에서는 에지를 이용하여 손실함수를 정의하고 생성된 이미지의 품질을 높이기 위하여 에지 검출을 적용한 eGAN을 실험하였다. 실험 결과 eGAN은 GAN과 비교해보면 eGAN이 더 빨리 필기체 손글씨 형태가 생성되고 이미지가 선명하게 보인다. eGAN 모델은 CCTV, 자연어 처리, 스마트시티, 자율주행, 장애물에 가려진 이미지 재생성에 활용될 것으로 기대된다.

### References


- [1] Y. J. Choi, "Deep Learning Approach for Generating Photorealistic Facial Images," Department of Media Engineering, Sogang University Graduate School of Media Studies. Doctoral dissertation, 2017.
- [2] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative Adversarial Nets," *Advances in neural Information Processing Systems*, pp.2672-2680, 2014.
- [3] Y. J. Cao, L. L. Jia, Y. X. Chen, N. Lin, C. Yang, and B. Zhang, "Recent Advances of Generative Adversarial Networks in Computer Vision," *IEEE Access*, Vol.7, pp.14985-15006, 2018.
- [4] M. Mirza and S. Osindero, "Conditional generative adversarial nets," <https://arxiv.org/abs/1411.1784> 2019.
- [5] Patterson, J. Zhao, M. Mathieu, and Y. Lecun, "Energy-based generative adversarial network," <https://arxiv.org/pdf/1609.03126>, 2019.
- [6] D. Berthelot, T. Schumm, and L. Metz, "BEGAN: Boundary Equilibrium Generative Adversarial Networks," arXiv: 1703.10717, 2019.
- [7] J. Dong, R. Yin, X. Sun, Q. Li, Y. Yang, and X. Qin, "Inpainting of Remote Sensing SST Images With Deep Convolutional Generative Adversarial Network," *IEEE Geoscience and Remote Sensing Letters*, Vol.16, No.2, pp.173-177, 2019.
- [8] M. Arjovsky, S. Chintala, and L. Bottou. "Wasserstein GAN," <https://arxiv.org/abs/1701.07875> 2019
- [9] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin, and A. Courville, "Improved training of Wasserstein GANs," <https://arxiv.org/pdf/1606.0349> 2019.
- [10] X. Mao, Q. Li, H. Xie, RYK. Lau, Z. Wang, and S. P. Smolley, "Least Squares Generative Adversarial Networks," *The IEEE International Conference on Computer Vision (ICCV)*, pp.2794-2802, 2017.
- [11] J. canny, "A Computational Approach to Edge Detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.PAMI-8, Iss.6, pp.679-697, 1986.



**이 초 연**

<https://orcid.org/0000-0001-6768-1312>  
e-mail : qecche77@knou.ac.kr  
2013년 한국방송통신대학교 컴퓨터과학  
(학사)  
2020년 한국방송통신대학원 정보과학과  
(석사)


관심분야: Artificial Intelligence, Deep Learning & GAN,  
IoT



**박 지 수**

<https://orcid.org/0000-0001-9003-1131>  
e-mail : jisupark@jj.ac.kr  
2013년 고려대학교 컴퓨터교육과(박사)  
2015년~2018년 충남대학교 초빙교수  
2018년~2019년 경기대학교 교양학부  
조교수

2019년~2020년 동국대학교 융합교육원 교수  
2020년~현 재 전주대학교 컴퓨터공학과 교수  
2020년~현 재 한국정보처리학회 이사 및 JIPS 간사  
2017년~현 재 HCIS 저널 편집위원  
관심분야: 분산 시스템, 모바일 클라우드 컴퓨팅, e-Learning,  
SW교육, 빅데이터 분석, IoT



**손 진 곤**

<https://orcid.org/0000-0002-0540-4640>  
e-mail : jgshon@knou.ac.kr  
1991년 고려대학교 전산학전공(박사)  
1991년~현 재 한국방송통신대학교  
컴퓨터과학과 교수  
1997년~1998년 State University of  
New York(Stony Brook)  
Visiting Professor

2000년~현 재 ISO/IEC JTC1/SC36 Korea Delegate  
2010년~2010년 한국정보처리학회 부회장  
2009년~현 재 이러닝학회 부회장  
관심분야: 컴퓨터통신망, 분산시스템, e-Learning, 정보기술  
표준화