

대형 이미지 데이터셋 구축을 위한 객체 엣지 기반 이미지 생성 기법

Object Edge-based Image Generation Technique for Constructing Large-scale Image Datasets

이 주 혁*, 김 미 희*

Ju-Hyeok Lee*, Mi-Hui Kim**

Abstract

Deep learning advancements can solve computer vision problems, but large-scale datasets are necessary for high accuracy. In this paper, we propose an image generation technique using object bounding boxes and image edge components. The object bounding boxes are extracted from the images through object detection, and image edge components are used as input values for the image generation model to create new image data. As results of experiments, the images generated by the proposed method demonstrated similar image quality to the source images in the image quality assessment, and also exhibited good performance during the deep learning training process.

요 약

딥러닝의 발전은 컴퓨터 비전 문제를 해결할 수 있지만, 높은 정확도를 위해서는 대규모 데이터셋이 필요하다. 본 논문에서는 객체 바운딩 박스와 이미지 엣지 성분을 이용한 이미지 생성 기법을 제안한다. 객체 탐지를 통해 이미지 내의 객체 바운딩 박스를 추출하고 이미지 엣지 성분을 함께 이미지 생성모델의 입력값으로 사용하여 새로운 이미지 데이터를 생성한다. 실험 결과, 제안 기법으로 생성된 이미지는 이미지 품질 평가에서 소스 이미지와 유사한 품질을 보였고, 딥러닝 훈련과정에서도 좋은 성능을 보였다.

Key words : data augmentation, image generation, Data preprocessing, image processing, deep learning

1. 서론

딥러닝의 발전으로 다양한 컴퓨터 비전 문제인 이미지 분류, 의료 데이터 생성, 객체 추적, 딥페이크 등 다양한 문제를 해결할 수 있다[1]. 딥러닝은 인공 신경망을 기반으로 학습하며, 훈련 데이터의 양이 증가할수록 성능이

향상되는 경향을 보인다[2]. 그렇기에 더 높은 수준의 딥러닝 모델을 설계하기 위해서는 대형 데이터셋이 필수적으로 필요하다. 하지만 원하는 모델에 맞는 대형 데이터셋을 구하기에는 어려움이 많으며, 직접 수집하기에도 많은 시간과 노력이 필요하다. 이 문제를 해결하기 위해서 데이터 증강 기술이 주목받고 있다[3].

* School. of Computer Engineering & Applied Mathematics, Computer System Institute, Hankyong National University

★ Corresponding author

E-mail : mhkim@hknu.ac.kr, Tel : +82 31-670-5167

※ Acknowledgment

Manuscript received Aug. 5, 2023; revised Sep. 6, 2023; accepted Sep. 25, 2023.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

데이터 증강 기술은 보유하고 있는 데이터셋을 여러 가지 방법을 통해 확대하여 실질적인 학습 데이터셋의 규모를 키울 수 있다. 이미지 데이터 증강은 기존의 이미지를 변형하거나 조합하여 새로운 이미지를 생성함으로써 데이터의 다양성을 높인다. 데이터 셋의 규모가 커져 자연스럽게 딥러닝도 더 많은 훈련을 할 수 있어 성능도 향상시킬 수도 있다. 의료 이미지, 자율주행 자동차, 스마트폰 카메라 어플 등 다양한 분야에서도 활용된다[4].

딥러닝 기반의 이미지 생성 모델에서 생성된 이미지의 눈에 띄는 오류나 불완전한 부분이 생기는 경우가 있다. 이미지나 동영상에서 색상, 패턴 등이 이상하게 보이는 현상 혹은 이미지 내의 구조가 불완전하거나 일그러지는 현상인 글리치(Glitch)가 발생한다[5].

선행 연구인 [6]에서 제안한 바운딩 박스를 결합한 이미지 생성 기법을 통해, 이미지 데이터 셋을 구축하고, 딥러닝 모델에 적용하여 정확도가 약 1.3% 향상된 것을 확인했다. 하지만, 이미지 생성 모델의 글리치가 발생하고, 이미지 품질이 떨어졌다.

이에 본 논문에서는 객체 바운딩 박스와 이미지 엣지 성분을 이용한 이미지 생성 기법을 활용하여 데이터 부족 문제와 글리치 현상을 해결하고자 한다. 이미지 내의 다른 노이즈 요소를 제거하기 위해 객체를 탐지하여 이미지 내의 객체 바운딩 박스를 추출해 자르고, 이미지 엣지 성분을 생성 모델에 입력해 이미지의 구조적 요소를 추가함으로써, 새로운 이미지 데이터를 생성한다. 또한, 제안 기법이 생성한 이미지 데이터의 품질과 학습 모델의 성능과 영향에 대해 분석하고 제안 기법의 유효성을 증명한다.

II. 배경 지식

1. 데이터 증강

데이터 증강은 데이터 부족 문제를 해결할 수 있는 방법론 중 하나이다. 데이터 부족은 기계 학습 모델 성능의 주요 제약 조건 중 하나로서, 특히 딥러닝 모델에서 학습에 필요한 대량의 데이터를 확보하기 어려울 때 발생한다. 이를 해결하기 위해서 데이터 증강이 사용될 수 있다. 데이터 증강은 기존의 제안된 학습 데이터 셋을 확장하고 다양성을 높이기 위해 사용되며 더 많은 훈련을 통해 모델의 성능도 향상시킬 수 있다[7]. 데이터 증강 기법은 다양한 분야에서 사용할 수 있는데 대표적인 예시로는 이미지, 텍스트 음성 등이 있다.

이미지 데이터의 경우 기하학적 변환, 색상변환 등 다

양한 기법이 존재한다. 기하학적 변환은 회전, 확대, 축소, 이동, 뒤집기 등[8] 여러 방법으로 이미지 데이터를 기하학적 변환한다. 색상 변환은 색상 공간을 변경, 밝기 조절, 콘트라스트 변경, 히스토그램 평활화 등[9] 다양한 기법으로 이미지 데이터를 색상 변환한다.

본 논문에서는 데이터 증강 기법 중에서 이미지 데이터 증강을 통해 데이터 부족 문제를 해결하고자 한다.

2. 객체 탐지 모델

객체 탐지는 컴퓨터 비전에서 주요한 연구 분야 중 하나로서, 이미지 또는 비디오에서 여러 객체의 존재, 위치, 종류를 찾아내는 작업이다. 객체 탐지는 객체인식, 객체 지역화, 분류, 경계 상자 추정(Bounding Box) 등이 포함된 차원에서 복잡한 작업을 수행한다. 객체 탐지 기술은 다양한 응용 분야에서 활용되며 자율 주행, 스마트 도시, 이미지 검색 등 다양한 응용 분야에서 중요한 역할을 한다. 객체 탐지 모델은 후보 영역 추출과 객체 분류를 두 단계로 나누어 처리한다. 첫 번째 단계에서는 이미지로부터 후보 객체들에 대한 이미지 영역(RoI: Regions of Interest)을 추출한다. 두 번째 단계에서는 후보 영역을 객체의 클래스에 따라 분류하고, 경계 상자를 조정하여 정확한 위치 및 크기를 얻는다.

본 논문에서는 객체 탐지 모델 구조를 바탕으로 이미지 내의 객체를 탐지하고 바운딩 박스를 기준으로 이미지 자르고 사용한다.

3. 이미지 생성 모델

이미지 생성 모델은 컴퓨터 비전과 인공지능 분야에서 광범위한 연구 분야 중 하나이다. 이미지 생성 모델은 기존 이미지와 동일한 특징을 가지고 있지만, 실제로는 존재하지 않은 새로운 이미지를 생성하는 모델이다. 이러한 기술은 그래픽, 디자인, 예술, 의료 이미지 등 여러 분야에서 사용되며, 가상 현실과 같은 신기술 작업에서도 활용된다. 이미지 생성 모델이 발전하며, 머신러닝, 딥러닝, 고성능 컴퓨팅 시스템 및 프로그래밍 라이브러리의 발전에 크게 기여했다. 대표적 이미지 생성 모델로서 오토인코더(Autoencoder)[10]와 GAN(Generative Adversarial Networks)[11]이 주목받고 있다.

오토인코더는 입력 데이터를 저차원 또는 전형적인 잠재 공간으로 압축 하는 과정인 인코딩을 거친 후, 압축된 잠재 공간을 사용해 원래의 데이터로 재구성하는 디코더 과정을 수행하는 인공신경망 구조이다. 오토인코더는 입력데이터의 노이즈 제거 및 비지도 사전학습에 활용되

며, 데이터 압축효과가 있어 이미지 생성에 사용 된다.

GAN은 생성기와 판별기라는 두 개의 신경망을 서로가 경쟁을 하면서 성능을 향상해 이미지를 생성하는 모델 구조를 가진다. 생성기는 가짜 이미지를 생성하고 판별기는 생성기가 만든 이미지를 진짜인지, 가짜인지를 판별한다. 이 과정을 계속 진행하여 서로 경쟁하는 구조를 가진다. 이 경쟁구조를 통해서 생성기는 점진적으로 기존 이미지와 비슷한 특징을 가지고, 판별기가 진짜인지 가짜인지 차이를 인식하기 어려운 이미지를 생성한다.

본 논문에서는 옛지 기반 이미지 생성 모델을 통해 대형 이미지 데이터셋을 구축한다.

III 제안 기법

Fig. 1.은 본 논문에서 제안하는 기법의 순서도다. 우선 a) 이미지 선정, 즉 입력된 이미지 데이터셋에서 소스 이미지와 참조 이미지를 선정한다. Fig. 1.-a) 과정은 이미지 데이터 셋에서 소스 이미지는 순차적으로 하나씩

선정이 된다. 참조 이미지는 소스 이미지를 제외한 이미지 중 랜덤으로 하나를 지정한다. 그 다음, b) 소스 이미지와 참조 이미지의 객체 추출, c) 소스 이미지의 엣지 추출, d) 생성 모델을 통한 이미지 생성 과정을 거친다. Fig. 1.의 모든 과정을 거쳐 새로운 이미지 데이터가 생성되면 다시 참조 이미지를 골라 Fig. 1.의 과정을 거친다.

1. 객체 추출

Fig. 1.-b) 과정인 객체 추출은 객체 탐지 모델을 통해 추출한다. 객체 탐지 모델에서는 소스 이미지와 참조 이미지가 각각 사용된다. 객체 탐지 모델을 통해 객체 추출을 하는 이유는 이미지 내의 특징을 제외한 다른 요소(배경, 잡음, 패턴 등)의 영향을 최대한 받지 않게 하도록 위함이다.

객체 탐지 모델은 이미지를 여러 격자로 나누고, 각 격자 셀마다 여러 개의 바운딩 박스 중에서 가장 큰 바운딩 박스를 선정한다. 즉 소스 이미지와 참조 이미지 내의 가장 큰 특징을 찾아 바운딩 박스를 지정한다. 바운딩 박

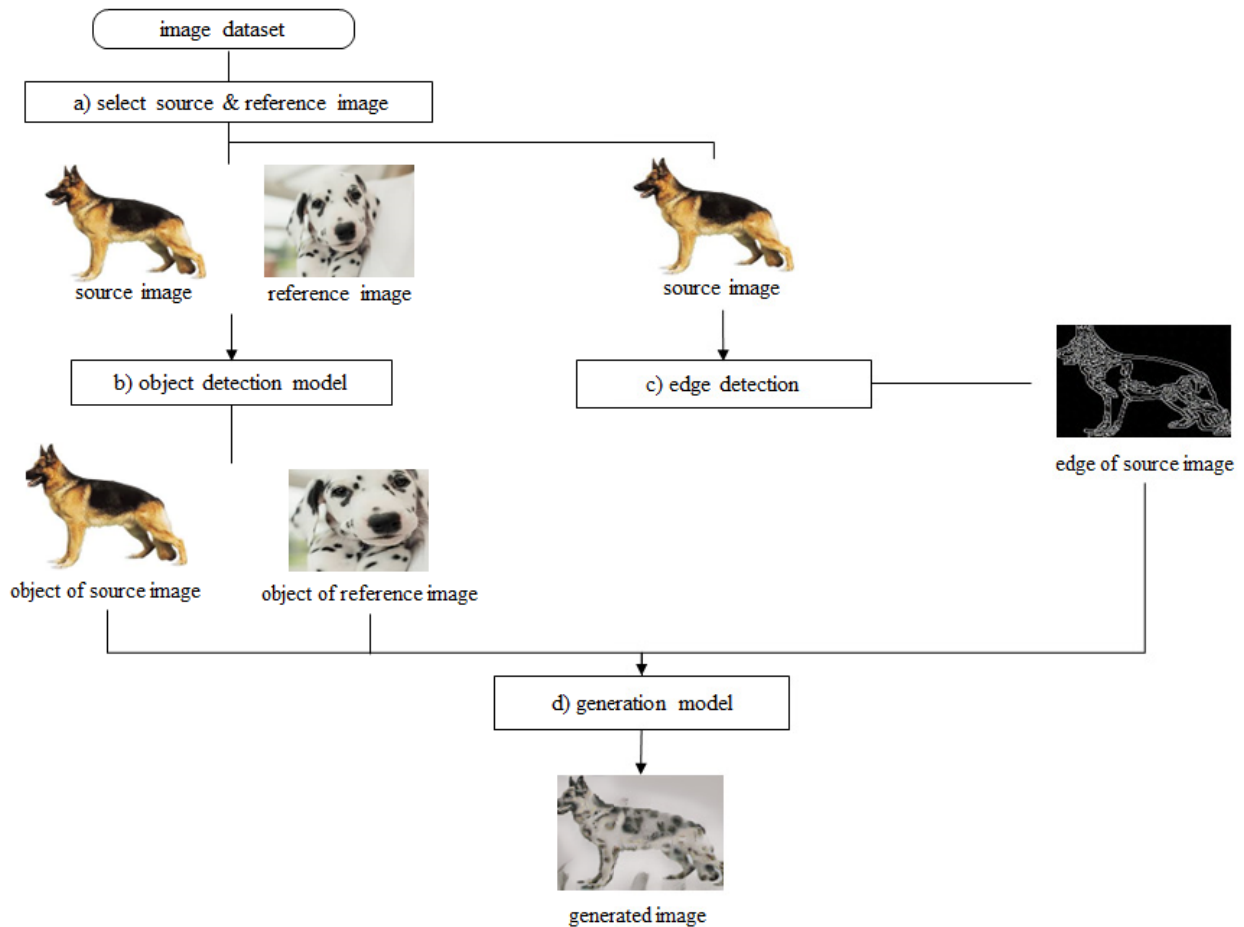


Fig. 1. proposed technique.

그림 1. 제안 기술

스를 기준으로 이미지를 자른다. 자르는 이유도 역시 다른 요소들을 제외하기 위함이다. 자른 이미지는 image object라는 이름으로 생성 모델의 입력값으로 사용된다. Fig. 2.는 소스 이미지의 객체 추출 결과 예시다.



Fig. 2. example of object detection model result.
그림 2. 객체 탐지 결과 예시

2. 이미지 엣지 추출

Fig. 1.-c) 엣지 추출(edge detection)은 이미지나 비디오에서 객체의 경계 즉, 엣지를 찾아내는 이미지 처리 기법이다. 이미지 내에서 객체나 구조물의 특징을 파악하는데 유용하며, 이 경계에서 이미지의 질감 색상 밝기 등이 급격하게 변한다.

3.1의 객체 추출을 통해서 소스 이미지와 참조 이미지의 특징이 가장 큰 요소들로 이미지를 구성할 수 있게 되었다. 하지만 이 두 가지를 통해서 이미지를 생성할 경우 소스 이미지와 참조 이미지 내의 구조적 요소가 결합하여 비정상적이고 품질이 떨어지는 이미지가 생성될 수도 있다. 이를 방지하기 위해서 부가적인 요소, 즉 엣지를 추가한다. 이미지 엣지 성분을 입력값으로 사용하여 생성 모델은 이미지 엣지요소를 기반으로 소스 이미지와 참조 이미지의 특징을 결합해 재구성하여 새로운 이미지를 만들기 위해서다. 이미지 엣지 성분은 이미지 내의 구조와 형태를 알 수 있다. 생성 모델에도 이 정보를 입력값으로 사용한다. 3.1에서 얻은 소스 이미지 객체를 엣지 추출을 통해 엣지 성분 이미지를 얻는다. 엣지 추출은 Gradient 기반 알고리즘을 사용할수 있는데, 본 논문에서는 Sobel[12] 알고리즘을 사용해 엣지 추출을 진행한



Fig. 3. example of edge detection.
그림 3. 엣지 추출 결과 예시

다. Fig. 3.은 엣지 추출 결과 예시다.

3. 생성 모델

객체 추출과 엣지 추출을 통해서 얻은 세 가지 입력값인 소스 이미지 객체, 참조 이미지 객체, 그리고 소스 이미지 엣지 성분을 이용해 딥러닝 기반 생성모델을 구축하였다. Fig. 4.는 생성 모델의 흐름도이다.

생성 모델은 크게 Fig. 4.의 인코더 디코더로 구성된다. 인코더는 소스 이미지와 참조 이미지를 잠재공간으로 인코딩하며, 디코더는 인코더에서 얻은 특징을 사용하여 소스 이미지를 재구성하는 디코더로 정의한다. 인코더 과정에서 합성곱 층(Conv2d layer)과 활성화 함수(activation fuction)를 사용해 특징을 추출한다. 디코더는 인코더에서 사용한 합성곱층과 반대로 전치 합성곱층을 이용하여 추출한 특징을 기반으로 다시 이미지를 재구성하여 복원하는 업 샘플링으로 이미지를 생성한다. 인코더와 디코더 층에 활성화 함수와 배치 정규화를 사용하여 이미지 생성 시 발생할 수 있는 노이즈를 줄이고 훈련 손실값을 최소화하고자 하였다. 생성모델 구조는 Fig. 4.의 인코더와 디코더의 구조를 반복하여 최적의 손실값을 얻는다.

인코더에서는 Fig. 4.의 conv2d, activation, conv2d, batchnorm2d, activation의 다운 샘플링 구조를 통해

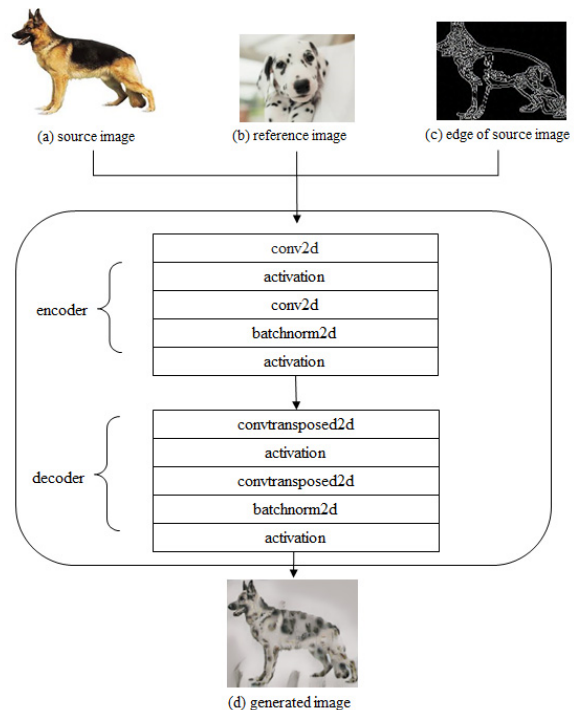


Fig. 4. flowchart of generation model.
그림 4. 생성 모델 흐름도

입력 이미지인 소스 이미지와 참조 이미지의 특징을 추출하고, 소스 이미지의 엣지 성분을 이미지의 구조성분을 참조에 특징을 추출한다. 디코더에서는 convtransposed2d, activation, convtransposed2d, batchnorm2d, activation의 엡샘플링 구조를 통해서 새로운 이미지를 생성한다. 여기서 손실함수로 MSE(Mean Squared Error) (1)를 사용한다. 손실함수 L을 사용하여, 생성 모델 학습 과정에서 MSE를 통해 얻은 값을 최소화하는 것을 목표로 하여, 이미지 내의 손실을 최대한 줄이고자 했다. 손실함수 L에서 n은 총 샘플 수이며, y_i 는 i번째 실제값, Y_i 는 i번째 예측 값이다. MSE 손실함수를 사용하는 이유는 소스 이미지와 생성된 이미지 간의 차이를 최소화하도록 학습하기 위해서이다.

$$L = \frac{1}{n} \sum_{i=1}^n (Y_i - y_i)^2 \quad (1)$$

인코더와 디코더를 결합하여 생성모델을 구축하고 소스 이미지, 참조이미지와 소스 이미지의 엣지 성분을 입력값으로 사용한다. 학습 루프를 통해서 모델을 에포크마다 새로운 이미지를 생성하고 손실 함수를 사용하여, 소스 이미지 간의 차이를 최소화한다. 모델의 매개 변수를 업데이트하면서 이 손실을 최소화한다. 학습이 완료되면서 모델은 세 가지 이미지를 입력 받아 소스 이미지를 재구성할 수 있다. 특히 이미지 엣지 성분을 이용해 소스 이미지와 비슷한 구조와 모양을 가진 이미지를 생성하고 손실을 최소화하며 훈련을 진행해 높은 품질의 이미지를 생성한다. 소스 이미지, 참조 이미지, 엣지 성분을 어떻게 조합하느냐에 따라라도 다양한 이미지 결과가 나올 수 있으며, 본 논문에서는 소스 이미지, 참조 이미지, 소스 이미지의 엣지 성분 만을 입력값으로 사용하는 경우만 고려하였다. Fig. 5.은 생성 모델을 통해 생성된 이미지의 예시이다.




Fig. 5. example of generation model results.
그림 5. 생성 모델 결과 예시

생성된 이미지들은 데이터셋 구축을 위해 높은 품질의 이미지들로만 구성이 되어야 한다. 이미지 품질평가를 통해 전처리 작업을 통해 데이터셋 구축을 진행한다.

IV. 실험 결과 및 분석

1. 실험 데이터

실험 데이터는 Kaggle dog vs cat 데이터[13] 중 강아지만 실험 데이터로 선정했다. 소스 이미지는 랜덤으로 선택한 2000장과 생성 모델을 통해 생성된 이미지 2000장을 통해 실험을 진행했다. 생성된 이미지들은 4.2의 이미지 품질평가를 거친 이미지들로 구성되어 하였다.

2. 이미지 품질평가

이미지 품질평가는 이미지의 왜곡이나 손실이 발생한 수준을 측정하는 기법이다. 본 논문에서는 품질평가를 통해 생성모델의 결과를 검증하여 실질적으로 사용할 수 있는 이미지인지 검증한다. 또한 품질평가 결과 임계값 이상인 이미지만 데이터셋에 포함시켜 품질이 좋은 이미지 데이터셋을 만드는 것을 목표로 한다.

이미지 품질평가는 PSNR(Peak Signal-to-Noise Ratio) [14]과 SSIM(Structural Similarity Index Measure) [15] 두가지를 사용한다. PSNR은 이미지 사이의 픽셀 강도 차이를 측정하는 방식으로 두 이미지 간의 평균 제곱 오차값을 사용한다. PSNR값이 높다면 이미지 간의 차이가 작다는 것을 의미하며, 더 좋은 품질임을 나타낸다. SSIM은 이미지의 구조, 명암 등 지각적 특징을 고려한 유사도 측정 지표이다. PSNR을 사용하는 이유는 소스 이미지의 엣지 성분을 활용하기 때문이다. 생성된 이미지와 소스 이미지 사이의 픽셀 강도 차이를 확인하여, 구조적 정보를 통해 이미지를 생성하였는지 판별하기 위해서다. PSNR과 비슷하게 생성된 이미지와 소스 이미지 사이의 지각적 특징을 파악하고, 유사도 측정을 통해 소스 이미지의 정보를 활용하였는지 판별하기 위해서이다. SSIM 값은 0부터 1사이의 값이며, 1에 가까우면 가까울수록 두 이미지 사이의 구조적 유사도가 높다는 것과 더 좋은 품질임을 나타낸다. 이를 통해서 제안 모델과 기타 모델들을 비교하여 이미지 품질의 유효성을 검증한다. 데이터셋 사용 기준은 제안 모델의 PSNR과 SSIM의 평균 값보다 높은 값들을 사용한다. Table 1.은 이미지 품질평가의 평균 결과이다. 이미지 생성 모델에서 많이 사용하는 GAN[10]과 Autoencoder[11]를 비교 모델로 사용했으며, 추가로 선행 연구[6]도 함께 이미지 품질 평가도 포함했다.

이미지 품질 평가는 생성 이미지에 사용된 소스 이미지를 PSNR과 SSIM의 기준으로 선정했다. 선행 연구의

생성모델[6]에 비해 약 2배정도 성능이 향상된 것을 확인했다. 또한 기존 이미지 생성 모델인 GAN과 Autoencoder 보다 약 20% 향상된 결과값을 얻었다. 제안 기법의 생성 이미지들이 소스 이미지와의 픽셀 강도 차이가 적으며, 구조적으로도 1에 가까운 결과가 나와 이미지 엣지 성분을 삽입하여 구조적 더욱 정교함을 유도한 것이 유효했음을 확인했다.

Table 1. image quality assessment.

표 1. 이미지 품질 평가 결과

Method	PSNR	SSIM
pervious papers[6]	14.43326	0.4938546
GAN[10]	26.24313	0.8546794
Autoencoder[11]	23.13433	0.8313468
Proposed Technique	31.24917	0.9353311

3. 딥러닝 모델 훈련 결과

생성 모델과 품질평가를 거쳐 이미지 데이터셋을 구축했다. 이 데이터셋이 실질적으로 딥러닝 모델에서도 사용할 수 있을지 검증하기 위해서 딥러닝 기반 이미지 분류 모델을 구축해 훈련을 진행했다. 이미지 분류 모델은 합성곱 신경망인 CNN을 기반으로 구축했으며, 강아지인지 아닌지에 대한 분류를 목표로 하는 모델을 구축했다. 제안 기법을 거치지 않은 소스 이미지 데이터셋인 a)와 새롭게 생성된 이미지 데이터셋 b) 마지막으로 a)와 b)를 합친 데이터셋 c) 총 3종류의 비교 실험을 진행했다. 생성 이미지 데이터셋인 b)의 경우가 과적합으로 인해서 생성 이미지의 구조에 맞게 딥러닝 모델이 훈련을 진행해 과적합이 발생할 수 있으므로, 소스 이미지와 생성 이미지를 합친 데이터셋 c)를 추가해 실험을 진행했다.

실험 목적은 제안 기법으로 생성된 이미지가 실질적으로 딥러닝 모델에서도 유효한지 여부를 보이기 위해 이 실험을 진행했다.

Fig. 6.과 Fig. 7.은 모델 예측 정확도와 loss 값을 비교한 그래프다. 실험결과 소스 이미지인 a)와 생성 이미지 b)가 예측 정확도와 손실값이 약 0.1의 차이를 보였다. 또한 소스 이미지와 생성 이미지를 합친 c) 데이터셋 실험결과 정확도는 약 6% 향상과 손실값이 약 26% 감소하는 결과값을 보였다.

실험 결과, 생성모델을 통해서 생성된 이미지들이 품질평가에서는 기존 연구들보다 약 20%의 높은 값을 보였다. 또한 딥러닝 모델 훈련 결과 실질적으로 사용할 수 있음을 보였다.

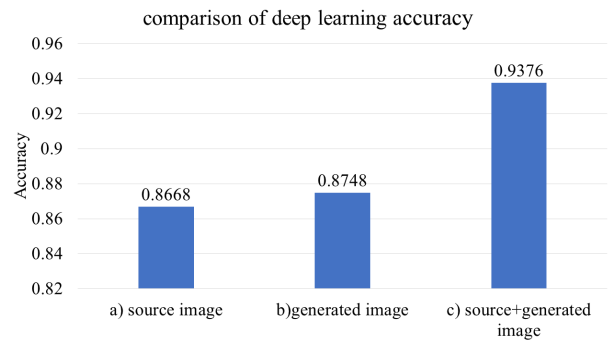


Fig. 6. comparison of deep learning accuracy.

그림 6. 딥러닝 정확도 결과 비교

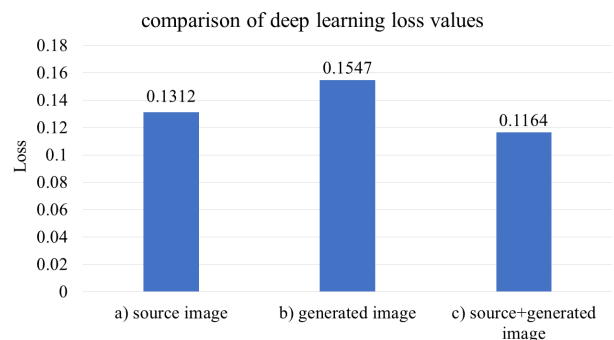


Fig. 7. comparison of deep learning loss values.

그림 7. 딥러닝 손실값 결과 비교

V. 결론 및 향후 연구

본 논문에서는 대형 이미지 데이터셋 구축을 위한 엣지 기반 이미지 생성 기법을 제안했다.

소스 이미지와 참조 이미지의 특징을 결합해 새로운 특징을 가진 새로운 이미지를 생성할 수 있다. 또한 소스 이미지의 엣지 성분을 추가해 선행 연구의 생성 모델[6]에 의해 생성된 이미지보다 구조적으로 더욱 정교하게 생성할 수 있게 되어, 결론적으로 품질이 향상된 이미지를 생성했다.

이미지 품질평가를 통해 생성된 이미지의 전처리 작업이 추가되어 평균보다 낮은 품질의 이미지를 제거한 데이터셋도 얻을 수 있었다.

딥러닝 모델 훈련 결과제안 기법을 통해 생성된 이미지 데이터셋의 유효성도 검증했다. 소스 이미지와 비슷한 결과를 보여줬다. 과적합을 방지하기 위해 소스 이미지와 제안기법을 통해 생성된 이미지의 훈련과정에도 좋은 성능을 보였다.

향후 연구에서는 최적의 결과를 얻기 위해 모델의 구조정보의 정교화와 학습과정 구성 요소를 연구하고자 한다. 또한 인코더와 디코더 과정의 훈련시간을 줄이기 위한 모델 구조도 연구하고자 한다.

References

- [1] LeCun Y, Bengio Y, Hinton G. "Deep learning," *Nature* 521, pp.436-444, 2015.
- [2] Shorten, C., Khoshgoftaar, T.M. "A survey on Image Data Augmentation for Deep Learning," *J Big Data* 6, No.60, 2019.
DOI: 10.1186/s40537-019-0197-0
- [3] C. Sun, A. Shrivastava, S. Singh and A. Gupta, "Revisiting Unreasonable Effectiveness of Data in Deep Learning Era," *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy, pp.843-852, 2017. DOI:10.1109/ICCV.2017.97
- [4] Athanasios Voulodimos, Nikolaos Doulamis, Anastasios Doulamis, Eftychios Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," *Computational Intelligence and Neuroscience*, vol. 2018. p.13, 2018.
- [5] T. Karras, S. Laine and T. Aila, "A Style-Based Generator Architecture for Generative Adversarial Networks," *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.4396-4405, 2019. DOI: 10.48550/arXiv.1812.04948
- [6] Ju-hyeok Lee, Mi-hui Kim. "Synthetic data generation technique using object bounding box and original image combination," *Conference of korea information processing society*, Vol.30, No.1, pp.476-478, 2023.
DOI: 10.48550/arXiv.1712.04621
- [7] Perez, Luis & Wang, Jason., "The Effectiveness of Data Augmentation in Image Classification using Deep Learning," *Computer Vision and Pattern Recognition*, p.8, 2017.
DOI: 10.48550/arXiv.1712.04621
- [8] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, "ImageNet classification with deep convolutional neural networks," *Advances in Neural Information Processing Systems (NIPS)*, pp.1097-1105, 2012. DOI: 10.1145/3065386
- [9] N. V. Chawla, K. W. Bowyer, L. O. Hall, W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-Sampling Technique," *Journal of Artificial Intelligence Research* 16, pp.321-357, 2002.
DOI: 10.48550/arXiv.1106.1813
- [10] Diederik P. Kingma, Max Welling., "Auto-Encoding variational bayes," *International conference on Learning Representations (ICLR)*, pp.14, 2014.
- [11] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y., "Generative adversarial nets," *Advances in Neural Information Processing Systems (NIPS)*, pp.2672-2680, 2014.
- [12] Gao, Wenshuo, et al. "An improved Sobel edge detection," *2010 3rd International conference on computer science and information technology*, Vol.5. 2010. DOI: 10.1109/ICCSIT.2010.5563693
- [13] SchubertSlySchubert, kaggle, Cats and Dogs dataset to train a DL model, cat and dog dataset [Internet], <https://www.kaggle.com/datasets/tongpython/cat-and-dog>
- [14] Yuanji. W, Jianhua. L, Yi, L, Yao. F, Qinzhong., J, "Image quality evaluation based on image weighted separating block peak signal to noise ratio," *IEEE, In International Conference on Neural Networks and Signal Processing*, Vol.2, pp.994-997, 2003. DOI: 10.1109/ICNNSP.2003.1281036
- [15] Wang, Zhou, et al. "Image quality assessment: from error visibility to structural similarity," *IEEE transactions on image processing*, Vol.13, No.4, pp.600-612, 2004. DOI: 10.1109/TIP.2003.819861

BIOGRAPHY

Ju-Hyeok Lee (Member)



2022 : BS degree in Computer Science and Engineering, Hankyong National University
2022~present : MS student in School of Computer Engineering & Applied Mathematics, Hankyong National University

Mi-Hui Kim (Member)

1997 : BS degree in Computer Science and Engineering, Ewha Womans University.

1999 : MS degree in Computer Science and Engineering, Ewha Womans University.

1999~2003 : Researchers at Switching & Transmission Technology Lab.(ETRI)

2007 : Ph.D. degree in Computer Science and Engineering, Ewha Womans University

2009~2010 : postdoctoral researcher of the department of computer science, North Carolina State University

2011~present : School of Computer Engineering & Applied Mathematics, Computer System Institute, Hankyong National University.