

GAN 알고리즘 개선을 위한 히스토그램 분석 기반 파손 영상 선별 방법

조진환¹ · 장종욱² · 장시웅^{2*}

A Broken Image Screening Method based on Histogram Analysis to Improve GAN Algorithm

Jin-Hwan Cho¹ · Jongwook Jang² · Si-Woong Jang^{2*}

¹Graduate student, Department of Software Convergence, Dong-Eui University, Busan 47340 Korea

^{2*}Professor, Department of Computer Engineering, Dong-Eui University, Busan, 47340 Korea

요 약

최근 데이터셋을 효율적으로 구축하는 방법으로 데이터 증강 기법과 관련하여 많은 연구가 이루어지고 있다. 이 중 대표적인 데이터 증강 기법은 생성적 적대 신경망(Generative Adversarial Network:GAN)을 활용하는 방법이며, 이는 생성자와 판별자를 서로 경쟁 학습시킴으로써 진짜 데이터와 유사한 데이터를 생성해내는 기법이다. 그러나, GAN을 학습할 때 환경 및 진행 정도에 따라 생성되는 유사 데이터 중에서 픽셀이 깨지는 파손 영상이 발생하는 경우가 있으며, 이러한 영상은 데이터셋으로 활용할 수 없고 학습 시간을 증가시키는 원인이 된다.

본 논문에서는 GAN 학습 과정에서 생성되는 영상 데이터의 히스토그램을 분석하여 이러한 파손 영상을 선별해 내는 알고리즘을 개발하였으며, 기존 GAN에서 생성되는 영상과 비교해 본 결과 파손 영상의 비율을 33.3배(3,330%) 감소시켰다.

ABSTRACT

Recently, many studies have been done on the data augmentation technique as a way to efficiently build datasets. Among them, a representative data augmentation technique is a method of utilizing Generative Adversarial Network (GAN), which generates data similar to real data by competitively learning generators and discriminators.

However, when learning GAN, there are cases where a broken pixel image occurs among similar data generated according to the environment and progress, which cannot be used as a dataset and causes an increase in learning time.

In this paper, an algorithm was developed to select these damaged images by analyzing the histogram of image data generated during the GAN learning process, and as a result of comparing them with the images generated in the existing GAN, the ratio of the damaged images was reduced by 33.3 times(3,330%).

키워드 : 생성적 적대 신경망, 유사 데이터, 파손 영상, 히스토그램, 선별 알고리즘

Keywords : Generative Adversarial Network, Similar Data, Broken Images, Histogram, Screening Algorithm

Received 19 October 2021, Revised 25 October 2021, Accepted 30 October 2021

* Corresponding Author Si-Woong Jang(E-mail:swjang@deu.ac.kr, Tel:+82-51-890-2354)

Professor, Department of Computer Engineering, Dong-EUI University, Busan, 47340 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.4.591>

print ISSN: 2234-4772 online ISSN: 2288-4165

© 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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

최근 딥러닝 환경이 확산됨에 따라 데이터셋 구축 방법에 대한 연구가 활발하게 이루어지고 있다. 기존 데이터셋 구축 방법은 인터넷상에 존재하는 데이터들을 어플리케이션이나 툴과 같은 자신들의 고유한 방법을 이용하는 방법[1-3], 특정 알고리즘의 구현을 통한 커스텀 데이터셋을 구축하는 방법[4] 등이 있다.

그러나 이러한 방법들은 사용자가 원하는 이미지뿐만 아니라 내용상 맞지 않는 이미지들도 많이 포함되어 있을 가능성이 있고[5], 인터넷상에 존재하는 데이터 중에서 딥러닝 모델의 학습을 위하여 대규모 대표 훈련 데이터를 수집하기 위한 환경의 표본 숫자가 너무 적거나 비현실적이고 사람 영상 데이터의 경우에는 초상권과 같은 액세스 문제가 발생한다는 단점이 있다[6]. 또한, 특정 알고리즘을 구현하여 커스텀 데이터셋을 구축하는 경우에는 효율적으로 데이터셋을 생성할 수는 있으나, 지정된 환경에서의 데이터셋을 구축하기 때문에 범용적으로 사용하기에는 어렵다는 단점이 있다.

이러한 문제를 해결하면서 효율적인 데이터셋 구축을 위하여 기존 인터넷상에 존재하는 데이터를 가져와 해당 데이터를 기반으로 기존 데이터와 유사한 새로운 데이터를 생성해내는 데이터 증강 기법과 관련된 연구가 이루어지고 있으며, 대표적으로 생성적 적대 신경망(GAN)을 활용한 데이터 증강 기법이 있다[7-14]. GAN을 이용한 데이터 증강 기법은 원하는 데이터를 일부 수집하여 새로운 데이터를 생성하여 데이터셋을 구축하기 때문에 기존 데이터셋 구축 방법의 단점인 데이터 확보에 있어 정확성 문제, 데이터 확보 환경 문제, 범용성 문제 등을 해결할 수 있다.

그러나 GAN을 학습하여 데이터 증강을 수행할 때, 학습 환경이나 학습 진행 정도에 따라 생성되는 새로운 영상 데이터 내에 픽셀 깨짐 현상이 발생하는 파손 영상이 생성되는 경우가 있다. 이러한 파손 영상의 경우에는 데이터셋으로 사용하기에 활용도가 떨어지며, 해당 데이터로 인하여 전체적인 학습 속도가 늦춰진다는 단점이 있다.

본 논문에서는 이와 같은 GAN 학습 과정에서 생성되는 영상 내의 히스토그램 분포를 분석하여 이러한 파손 영상을 미리 검토하여 선별해내는 알고리즘을 구현하여 기존 GAN 알고리즘의 단점을 개선한다.

II. 관련 연구

GAN을 통한 데이터 증강 기법을 이용하여 효율적으로 데이터셋을 구축하는 연구가 활발하게 이루어지고 있으며, 대표적으로 WGAN을 이용한 데이터 증강 기법[8], GAN과 GSVD 기반 LDA를 이용한 효과적인 학습 데이터셋 제작 기법[9], GAN을 이용한 매칭 의상 디자인 생성 기법[10], 마지막으로 StyleGAN이 있다[13, 14].

2.1. Generative Adversarial Nets

최초로 제안된 GAN으로, 새로운 이미지를 생성하는 생성자 Generator와 샘플 데이터와 생성자가 생성한 이미지를 구분하는 판별자 Discriminator 두 개의 네트워크 구조를 제안하였다. 해당 네트워크의 생성자 G와 판별자 D의 수식은 아래 수식 (1)과 같다.

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

판별자 D는 $V(D, G)$ 가 최대가 되도록 하는 것이다. 이를 위하여 D는 $D(x)=1$, $D(G(z))=0$ 이 되도록 하는 것이 목표이다. 이는 진짜 데이터를 입력으로 받았을 때, 1을 출력하고, 생성자 G에서 생성된 가짜 데이터를 입력으로 받았을 때 0을 출력하는 것이다. 생성자 G는 $V(D, G)$ 가 최소가 되도록 하는 것이며 G는 D가 가짜 데이터에 대해서 1을 출력하게 하도록 $D(x)=0$, $G(G(z))=1$ 이 되는 것을 목표로 학습을 수행한다. 이처럼 생성자는 판별자를 속이면서 이미지를 잘 생성하려고 하며, 판별자는 주어진 이미지가 진짜인지 생성자가 생성한 이미지인지 판별하도록 하는 경쟁 학습을 통해 결과적으로 생성자에서 진짜와 유사한 새로운 이미지를 생성하도록 한다.

이 연구에서는 단순 네트워크 구조만 설계하였을 뿐, 생성되는 영상에 대한 선별 알고리즘이 없어 GAN 학습 초기 과정이나 학습 중에 발생하는 파손 영상에 대해서 처리할 방법이 없다.

2.2. WGAN을 이용한 데이터 증강 기법

WGAN에서는 기존 GAN과 유사한 형태의 네트워크 구조를 가지고 있으며, MNIST와 NIST 손글씨 데이터셋을 활용하여 데이터 증강을 수행하였다.

또한, WGAN에서는 생성되는 영상에 대해서 선별

알고리즘을 학습된 판별자의 입력으로 사용하여 나온 결과값들의 평균과 표준편차를 이용하여 일정 범위 내의 영상만을 새로운 데이터셋에 추가하는 형태로 구현하였으나, 파손 영상을 제대로 선별하지 못하고 결과에 파손 영상이 존재하는 등의 정확한 선별 알고리즘으로써의 역할을 수행하지는 못하였다.

2.3. StyleGAN

StyleGAN은 Generator 네트워크에서 각 레이어마다 스타일 정보를 입히는 방식으로 학습을 수행한다. 영상의 스타일(성별, 포즈, 머리색, 피부톤 등)을 변경할 수 있으며, 기존 입력 영상 z 가 특정 데이터셋의 분포를 그대로 따라가는 경향을 방지하기 위하여 Mapping Network를 추가하여 나온 새로운 결과값 w 를 활용하여 스타일을 더욱 다양하게 바꿀 수 있도록 하였다.

StyleGAN은 여러 GAN 알고리즘 중 가장 최근에 나온 GAN 알고리즘으로서 학습 성능이나 결과치가 매우 우수한 수준이다. 그러나, 학습에 필요한 그래픽 메모리 등의 컴퓨팅 자원이 상당히 높은 수준을 요구하기 때문에 실질적으로 이를 활용하는데 어려움이 있다.

Table. 1 StyleGAN2 energy consumption[15]

Image size	Total iter	1 GPU	2 GPUs	4 GPUs	8 GPUs	GPU mem
1024*1024	25000	69d 23h	36d 4h	18d 14h	9d 18h	13.3 GB
1024*1024	10000	27d 23h	14d 11h	7d 10h	3d 22h	13.3 GB
256*256	25000	32d 13h	16d 23h	8d 21h	4d 18h	6.4 GB
256*256	10000	13d 0h	6d 19h	3d 13h	1d 22h	6.4 GB

III. 파손 영상 선별 알고리즘 개발

본 연구에서는 GAN 알고리즘을 이용하여 Face Generation을 수행하고, 효율적인 데이터셋을 구축하기 위해 파손 영상 선별 알고리즘을 개발하였다. 해당 알고리즘은 기존에 존재하는 사람 얼굴 영상 중 일부를 선택한 후, 선택된 영상을 조합하여 새로운 얼굴 영상을 생성하는 방식으로 수행되는 알고리즘으로, 위 과정의 반복을 통해 데이터를 생성한다.

3.1. Face Generation GAN 결과 분석

파손 영상 선별 알고리즘의 기반이 되는 히스토그램 분포를 분석하기 위하여 Face Generation GAN의 결과로 생성된 영상 중 데이터셋으로의 활용 가치가 있는 유효 영상과 픽셀 깨짐 현상이 발생한 파손 영상 각각의 히스토그램을 그림 1, 2와 같이 분석하였다. 분석 결과, 유효 영상은 전체적으로 색상별 분포가 유사하게 분포하는 것을 확인할 수 있었으며, 파손 영상의 경우 대부분의 영상이 255 색상 값을 갖는 분포에 차이가 있거나, 전체적으로 분포가 많은 것을 확인할 수 있었다.

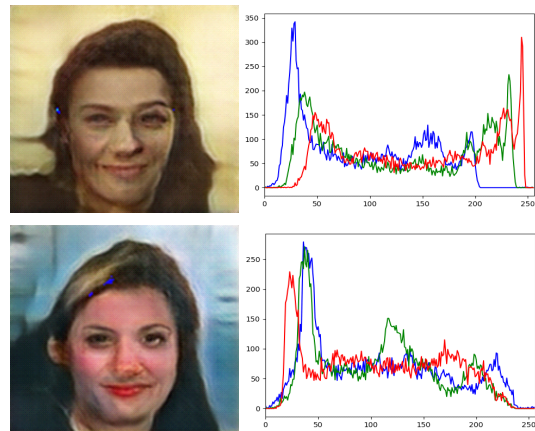


Fig. 1 Valid images and their histograms

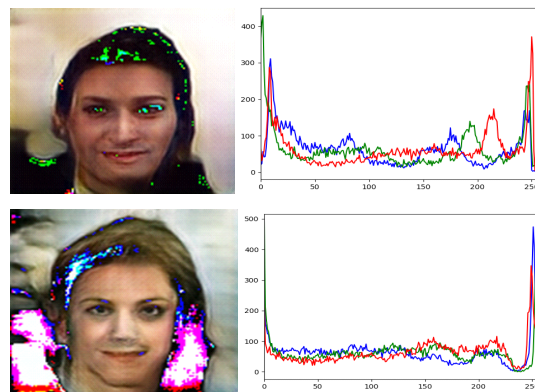


Fig. 2 Broken images and their histograms

3.2. 단일 색상 기반 파손 영상 선별 알고리즘 설계

3.1에서 분석한 결과를 토대로 단일 색상 기반 파손 영상 선별 알고리즘을 아래와 같이 설계하였다.

영상 내 히스토그램을 배열로 가져와 색상별로 행을

나누고, 각 행의 255 색상 값에 해당하는 값을 분석하여 그 결과에서 가장 많은 분포를 가진 값과 가장 적은 분포를 가진 값의 차이를 계산하여 임계값 이상일 경우 파손 영상으로 판단하고, 해당 영상의 저장 과정을 수행하지 않는다. 단일 색상 기반 파손 영상 선별 알고리즘을 포함한 Face Generation GAN의 흐름도는 그림 3과 같다.

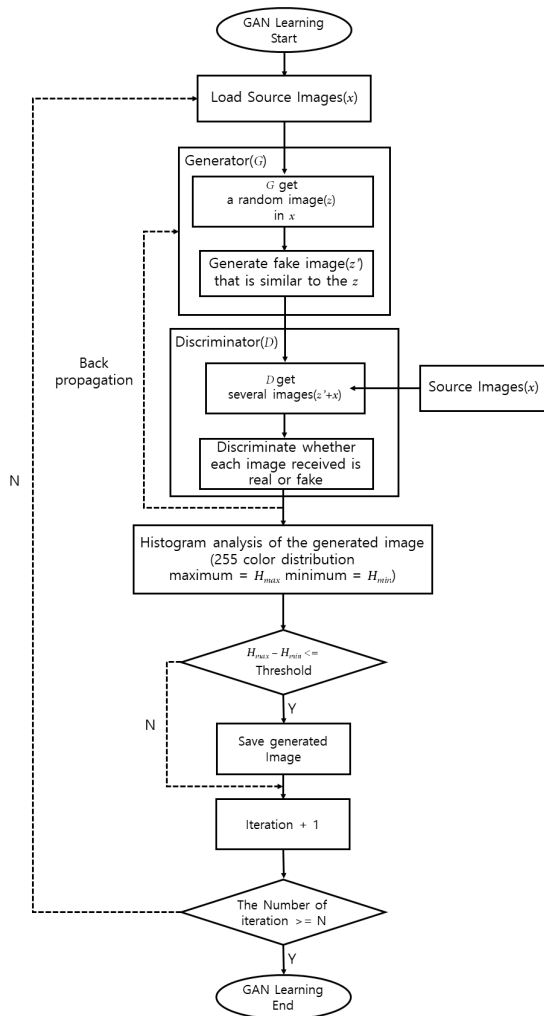


Fig. 3 Flowchart of face generation GAN including the single color-based broken image screening algorithm

3.3. 단일 색상 기반 파손 영상 선별 알고리즘 결과 분석

3.2에서 설계한 단일 색상 기반 파손 영상 선별 알고리즘에서 임계값을 40, 20으로 두고 각각 실험한 결과를 분석하였다. 실험 결과는 아래 표 2와 같다.

Table. 2 Single color-based broken image screening algorithm test results

	Number of images generated	Number of broken images	Occurrence rate(%)
Existing GAN	2,500	396	15.84
Threshold 40	2,500	69	2.76
Threshold 20	2,500	23	0.92

위 실험 결과, 파손 영상 선별 알고리즘을 탑재하지 않은 기존 GAN에서 본 연구에서 개발한 단일 색상 기반 파손 영상 선별 알고리즘을 임계값 40으로 설정하고 적용한 결과 파손 영상의 발생 빈도가 약 83% 감소하였으며, 임계값을 20으로 설정하고 적용한 결과 기존 GAN에서 파손 영상 발생 빈도를 약 94% 감소시켰다.

그러나, 단일 색상 기반 파손 영상 선별 알고리즘에서는 그림 4와 같이 255 색상 값 분포의 전체 합계가 일정 수 이상일 때 발생하는 흰색으로의 픽셀 깨짐 현상이 발생한 파손 영상을 제대로 선별하지 못하였다.




Fig. 4 Broken images and their histograms with a total of 255 color distributions of more than a specific number

또한, 그림 5와 같이 단일 색상 기반 파손 영상 선별 알고리즘에서 조건으로 사용되었던 255 색상 값을 가지지 않고 일정 이상의 색상 값 범위에서의 히스토그램 분포의 최댓값과 최솟값의 차이를 가지는 파손 영상에 대해서도 선별해내지 못하였다.




Fig. 5 Broken images and their histograms with a difference in color distributions above 240 value

3.4. 복합 색상 기반 파손 영상 선별 알고리즘 설계

3.3에서 설계한 단일 색상 기반 파손 영상 선별 알고리즘에서 발생한 문제점을 해결하기 위하여 복합 색상 기반 파손 영상 선별 알고리즘을 설계하였다. 복합 색상 기반 파손 영상 선별 알고리즘을 포함한 Face Generation GAN의 흐름도는 아래 그림 6과 같다.

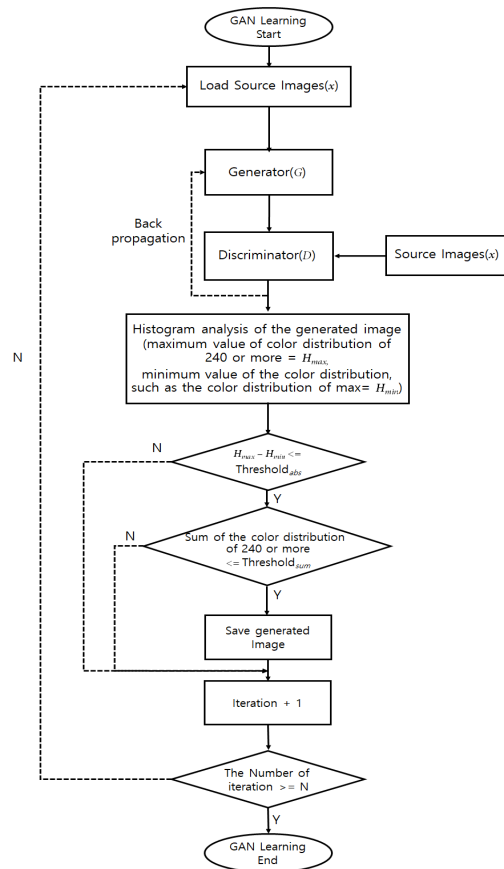


Fig. 6 Flowchart of face generation GAN including the multi color-based broken image screening algorithm

먼저, 단일 색상 기반 파손 영상 선별 알고리즘에서 255 색상 분포의 최댓값과 최솟값의 차이를 계산하여 파손 영상 여부를 판단하던 것을 240 이상의 색상 분포에서의 최댓값을 구하고 해당 최댓값이 가지는 색상 값의 최솟값을 구하여 그 차이를 계산한다. 이때 해당 값이 임계값 이상일 경우 파손 영상으로 판단한다. 또한, 앞선 조건에서 걸러지지 않고 240 이상의 색상 분포가 유사하게 높게 분포되어 합계가 일정 수 이상인 흰색으

로 픽셀 깨짐이 발생하는 파손 영상도 선별하기 위하여 240 이상의 색상 분포에서 최댓값을 가지는 색상 값과 같은 색상 값을 가지는 다른 색상에서의 분포 합계가 일정 수 이상일 경우 흰색으로 픽셀 깨짐 현상이 발생하는 파손 영상으로 판단하여 저장 과정을 수행하지 않도록 한다.

3.5. 복합 색상 기반 파손 영상 선별 알고리즘 결과 분석

3.3에서 설계한 복합 색상 기반 파손 영상 선별 알고리즘에서 색상 임계값을 40으로, 합계 임계값을 1,000으로 설정하고 기존 GAN, 단일 색상 기반 영상 선별 알고리즘과 비교한 결과는 아래 표 3과 같다.

Table. 3 Multi color-based broken image screening algorithm test results

	Number of images generated	Number of broken images	Occurrence rate(%)
Existing GAN	2,500	396	15.84
Single color-based Algorithm(20)	2,500	23	0.92
Multi color-based Algorithm	2,500	12	0.48

위 결과를 바탕으로 복합 색상 기반 파손 영상 선별 알고리즘 사용 시, 단일 색상 기반 영상 선별 알고리즘을 충분히 개선한 성능을 보여줌을 확인할 수 있었으며, 복합 색상 기반 파손 영상 선별 알고리즘은 기존 GAN의 생성되는 파손 영상의 약 97%를 선별해내었다.

그러나, 최적화 문제로 그림 7과 같은 파손 영상이 발생하는 경우가 있었으며, 해당 현상은 임계값의 조절을 통하여 알고리즘의 최적화를 수행하여 개선할 예정이다.




Fig. 7 Broken images and their histograms that occurred in the improved broken image screening algorithm

V. 결 론

본 논문에서는 기존 GAN 알고리즘의 개선을 위하여 GAN 학습을 통해 생성된 영상 내 히스토그램을 분석하고, 분석한 히스토그램을 기반으로 생성된 영상의 파손 여부를 판단하여 선별하는 파손 영상 선별 알고리즘을 개발하였다. 본 연구에서 개발한 파손 영상 선별 알고리즘은 딥러닝 환경을 사용함에 있어 컴퓨팅 퍼포먼스가 상대적으로 부족한 PC에서도 GAN을 효율적으로 사용할 수 있게 하며, 기존 GAN에서 생성되는 파손 영상의 비율을 33.3배(3,330%) 감소시켰다. 또한, 임계값 변경을 통하여 더욱 유연한 영상 선별을 수행할 수 있을 것으로 예상된다.

추후 연구를 통하여 파손 영상의 유형을 학습하여 유형별 선별 알고리즘을 개발하고, 기존에 존재하는 데이터셋만 학습시킨 결과와 파손 영상 선별 알고리즘을 결합한 GAN의 학습을 통해 생성된 데이터와 기존 데이터를 합쳐 생성한 데이터셋을 각각 딥러닝 엔진에 학습시킨 결과를 비교하여, 파손 영상 선별 알고리즘 및 데이터 증강의 우수성을 검증하고자 한다.

ACKNOWLEDGEMENT

This research was supported by the MSIT (Ministry of Science and ICT), Korea, under the Grand Information Technology Research Center support program(IITP-2022-2020-0-01791) supervised by the IITP(Institute for Information & communications Technology Planning & Evaluation)

References

- [1] K. M. Choi, Y. M. Kim, J. P. Shin, S. M. Sung, and B. K. Lee, "Data set design and implementation for Assistive walking device AI service construction," in *Proceedings of the Korean Society of Computer Information Conference*, Busan, vol. 29, no. 1, pp. 227-229, Jan. 2021.
- [2] J. S. Lee, B. K. Ko, E. S. Kang, H. J. Choi, J. O. Kim, and B. K. Lee, "AI Learning Cookie Image Data Set Construction," in *Proceedings of the Korean Society of Computer Information Conference*, Jeju, vol. 28, no. 2, pp. 347-349, Jul. 2020.
- [3] H. C. Lee, S. Y. Shin, "Development of Data Collection System using Google Environment," in *Proceedings of The Korean Institute of Information and Communication Science*, Busan, vol. 23, no. 2, pp. 704-705, Oct. 2019.
- [4] J. S. Kim and S. W. Jang, "Construction Method of Multifaceted Image Datasets for Improving Object Recognition Rate in Deep Learning System," in *International Conference on Future Information & Communication Engineering*, Online, vol. 12, no. 1, pp. 144-147, Feb. 2021.
- [5] E. S. Park, Y. J. Yang, J. H. Jeon, and E. S. Ryu, "Image Web Crawling Program for Artificial Intelligence Datasets," in *Proceedings of the Korean Society of Broad Engineers*, Seoul, p. 55, Nov. 2018.
- [6] J. H. Choi, K. M. Irick, J. Hardin, W. Qiu, A. Yuille, J. Sampson, and V. Narayanan, "Stochastic Functional Verification of DNN Design through Progressive Virtual Dataset Generation," in *2018 IEEE International Symposium on Circuits and Systems(ISCAS)*, Florence, pp. 1-5, 2018.
- [7] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative Adversarial Networks" arXiv: 1406.2661 [stat.ML], Jun. 2014. Available: <https://arxiv.org/abs/1406.2661>
- [8] S. H. Lim, Y. G. Shin, C. H. Yoo, H. K. Lee, and S. J. Ko, "Data Augmentation method using WGAN," in *2017 Institute of Electronics and Information Engineers Fall Conference(IEIE)*, Incheon, pp. 516-519, Nov. 2017.
- [9] Y. J. Yang, Y. G. Hong, and J. H. Park, "Efficient Learning Dataset Generation and Data Selection Using Generative Adversarial Network and GSVD-Based Linear Discriminant Analysis," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 45, no. 7, pp. 1166-1173, Jul. 2020.
- [10] M. Önder and Y. S. Akgül, "Automatic Generation of Matching Clothes Design Using Generative Adversarial Networks," in *2020 28th Signal Processing and Communications Applications Conference (SIU)*, Gaziantep, pp. 1-4, 2020.
- [11] J. H. Jeong, J. W. Kim, and H. T. Kim, "Expanding Training Datasets for Image Classification Network using GAN," in *Proceedings of The Korean Institute of Information and Communication Science*, vol. 23, no. 2, pp. 75-76, Oct. 2019.
- [12] S. J. Bae, M. G. Kim, and H. K. Jung, "GAN System Using Noise for Image Generation," *Journal of the Korea Institute*

- of *Information and Communication Engineering*, vol. 24, no. 6, pp. 700-705, Jun. 2020.
- [13] T. Kerras, S. Laine, and T. Aila, "A Style-Based Generator Architecture for Generative Adversarial Networks," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, CA: California, pp. 4401-4410, 2019.
- [14] T. Kerras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen, and T. Aila, "Analyzing and Improving the Image Quality of StyleGAN," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, WA: Washington, pp. 8110-8119, 2020.
- [15] NVlabs / StyleGAN2 - Training Networks [Internet]. Available: <https://github.com/NVlabs/stylegan2>



조진환(Jin-Hwan Cho)

2020년 2월 동의대학교 컴퓨터과학과 공학사
2022년 2월 동의대학교 소프트웨어융합학과 공학석사 졸업예정
※ 관심분야 : 영상처리, 모바일 소프트웨어, 스마트 자동차, 데이터베이스



장종욱(Jongwook Jang)

1987년 부산대학교 계산통계학과 이학사
1991년 충남대학교 계산통계학과 이학석사
1995년 부산대학교 컴퓨터공학과 공학박사
1987년~1995년 한국전자통신연구소 연구원
1995~현재 동의대학교 컴퓨터공학과 교수
※ 관심분야 : 유무선통신시스템, 자동차네트워크, 블록체인, 딥러닝



장시웅(Si-Woong Jang)

1984년 부산대학교 계산통계학과 이학사
1993년 부산대학교 전자계산학과 이학석사
1996년 부산대학교 전자계산학과 이학박사
1986년~1993년 대우통신(주) 종합연구소
2004년~2005년 University of Texas at Dallas 객원교수
1996년~현재 동의대학교 컴퓨터공학과 교수
※ 관심분야 : IT융합, 차량용 네트워크, 데이터베이스