

SRGAN 기반의 CCTV 영상 화질 개선 기법

하현수[†], 황병연^{**}

Enhancement Method of CCTV Video Quality Based on SRGAN

Hyunsoo Ha[†], Byung-Yeon Hwang^{**}

ABSTRACT

CCTV has been known to possess high level of objectivity and utility. Hence, the government has recently focused on replacing low quality CCTV with higher quality ones or even by adding high resolution CCTV. However, converting all existing low-quality CCTV to high quality can be extremely costly. Furthermore, low quality videos prior to CCTV replacement are likely to be of poor quality and thus not utilized correctly. In order to solve these problems, this paper proposes a method to improve videos quality of images using SRGAN(Super Resolution Generative Advisory Networks). Through experiments, we have proven that it is possible to improve low quality CCTV videos clearly. For this experiment, a total of 4 types of CCTV videos were used and 10,000 images were sampled from each type. Those images could then be used for machine learning. The fact that the pre-process for machine learning has been done manually and the long time that required for machine learning seems to be complementary.

Key words: CCTV, SRGAN, Video Quality, Machine Learning, Performance Evaluation

1. 서 론

CCTV(Closed Circuit Television)는 폐쇄 회로 텔레비전을 말하며 산업용, 의료용, 교통 감시용, 방재용 및 실내의 화상정보 전달용 등 용도가 다양하다. 특히 우범지대나 무인 감시용으로 보안이 필요한 은행에서 사용되는 경우가 많다. CCTV 설치를 통해 범죄 예방 및 억제효과와 범인 체포의 용이성, 시민들의 범죄에 대한 심리적 두려움 감소, 치안인력 보완 효과를 얻을 수 있다. 그러나 일반인들의 초상권 및 사생활 침해가 문제점으로 지적되고 있다[1].

최근 경기도 재난안전본부가 재난 현장을 높은 배율로 확대할 수 있는 고성능 카메라를 활용하여 원거리부터 건물 내부까지 실시간으로 감시할 수 있는

시스템을 구축하였다. 경기도 전역에 설치된 9만 4000여대의 CCTV 화면을 재난본부 상황실에서 실시간으로 감시하는 것이다. 이처럼 재난에서도 CCTV의 활용이 중요해지고 있으며 통신기술과 접목되어 점차 증대되는 추세이다.

2016년 ‘알파고’를 통해 인공지능이 전 세계의 관심을 끌게 되었다. 인공지능은 4차 산업혁명의 핵심 요소로 떠오르고 있으며 적용 분야도 다양하다. 인공지능 구현의 기반이 되는 부분인 딥 러닝은 컴퓨터가 여러 데이터를 이용해 마치 사람처럼 스스로 학습할 수 있도록 인공 신경망(Artificial Neural Network)을 기반으로 구축한 기계 학습 기술이다. 딥 러닝을 활용하여 인간의 두뇌가 수많은 데이터 속에서 패턴을 발견한 뒤 사물을 구분하는 정보처리 방식을 모방

* Corresponding Author : Byung-Yeon Hwang, Address: (14662) 43 Jibong-ro, Bucheon-si, Gyeonggi-do, Korea, TEL : +82-2-2164-4363, FAX : +82-2-2164-4581, E-mail : byhwang@catholic.ac.kr

Receipt date : Nov. 27, 2017, Revision date : Jan. 17, 2018
Approval date : Feb. 8, 2018

[†] Dept. of Computer Eng., Graduate School, The Catholic University of Korea
(E-mail : hss0924@catholic.ac.kr)

^{**} Dept. of Computer Eng., Graduate School, The Catholic University of Korea

해 컴퓨터가 사물을 분별하도록 기계를 학습시킨다. 딥 러닝은 영상인식, 음성인식, 번역 등 다양한 분야에 이용되면서 광범위하게 활용되고 있다[2]. 딥 러닝 중에서도 최근 주목 받고 있는 기술은 생성적 대립 신경망이라고 알려진 GAN(Generative Adversarial Networks)이다. 본 논문에서는 GAN 알고리즘 중에서 SRGAN 딥러닝 기법을 활용하여 저화질의 CCTV 영상 화질을 개선시키는 실험을 진행하여 화질 개선이 가능함을 보이고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 GAN 딥러닝 기법과 관련 연구에 대해서 소개하고 3장에서는 전체적인 영상 화질 개선 모델의 실험 방법과 과정에 대해서 살펴본다. 이후 4장에서 실험 데이터를 통해 기존의 CCTV 영상과 화질 개선 기법을 거친 후의 영상의 차이점을 보인다. 마지막으로 5장에서 결론과 한계점, 향후 계획을 설명한다.

2. 관련 연구

[3]은 최근 주목받는 주제인 GAN에 관한 개념과 배경 그리고 구조 분석과 적용사례를 설명한다. GAN은 서로 대립적인 관계에 있는 두개의 네트워크를 구성하여 서로 대립하는 과정에서 훈련 타겟을 생성하는 방법을 알도록 학습시키는 구조이다. 그러나 [3]에서는 현재 GAN으로 생성한 이미지의 해상도가 낮고, 아직 완벽하지 못한 문제점이 있다고 지적한다.

[4]는 GAN의 한 종류인 Cycle GAN 기법을 활용하여 수목화 스타일 이미지를 생성하는 GANMOOK을 개발하고 다른 기존 방법들과 학습 결과를 비교한다. [5]는 SRGAN 기법을 단일 이미지에 적용하여 슈퍼 해상도의 정확성과 속도의 비약적인 발전을 시켰다. 기존의 GAN보다 속도가 빠르고 깊은 계층을 가진 인공 신경망을 적용한 SRGAN을 사용하였다. 본 논문에서는 [5]에서 사용한 SRGAN 기법의 과정을 참조하여 실험을 진행하였다. [6]은 이미지를 생성하기 위한 다중 클래스 이미지 데이터를 학습하여 다양한 형태의 이미지를 생성할 수 있는 MC-GAN 모델을 제안하였다. 이를 위해 [6]에서 제안하는 모델은 이미지와 더불어 이미지의 클래스 정보를 모델 학습에 반영한다. [6]에서는 MC-GAN을 이용하여 다양한 클래스에 대한 이미지를 생성할 수 있으며, 다중 클래스의 이미지를 생성함에 있어 조건부 GAN보다 성능이 우수하다는 것을 보여 주었다. [7]에서

는 모바일 게임 데이터의 불균형 문제를 해결하기 위한 InfoGAN 기반의 오버샘플링 기법을 제안하였다. 실험을 통해 제안된 기법이 불균형 데이터 문제를 해결하기 위한 오버샘플링 방법으로 가능성이 있음을 확인하였다.

[8]은 비디오 영상 압축 왜곡 제거를 위해 GAN 모델을 적용한 CNN 모델을 제안하였다. 결과적으로 제안 모델에 압축된 영상을 입력한 뒤, 압축이 제거된 영상을 효과적으로 도출했다. 본 논문에서 제안하는 기법은 기존의 GAN 모델이 대체로 이미지를 데이터로 사용한 것과 다르게 [8]처럼 비디오 데이터를 사용했다.

[9]는 GAN을 통해 데이터 분포를 파악하고 생성하는 모델 G와 표본을 훈련 데이터와 비교하여 유사 확률을 추정하는 식별 모델 D의 두 가지 모델을 제안하였다. 모델 G와 D가 다중 퍼셉트론에 의해 정의되는 경우 전체 시스템을 역 전과 훈련이 가능함을 보여 프레임 워크의 유용성을 입증하였다.

[10]은 효과적인 슈퍼 해상도를 위해 다양한 신경망 연구를 진행하였다. 기존의 선형 필터를 적용한 연구들에 비하여 신경망 학습을 통해 얻어진 필터를 적용한 기법들이 좋은 성능을 보임을 설명하였다.

[11]은 높은 정밀도의 단일 이미지 초해상도 개선 기법을 제시하였다. ImageNet 분류에 사용되는 인공신경망 네트워크를 사용하였고 네트워크의 깊이가 증가함에 따라 정확도가 크게 향상되었음을 보였다. 실험 결과 기존의 SRCNN 기법보다 정확도가 높고, 결과가 시각적으로 다소 개선되었다.

[12]에서는 VDSR에 ESPCN에 적용된 디컨볼루션 레이어를 적용하여 SR 이미지를 출력하는 기법을 제안한다. VDSR은 단일 영상 초해상도용 CNN 구조이며 화질 성능이 높은 기법이다. 제안한 기법을 통해 전처리 연산을 제거함으로써 사용하는 메모리와 연산량을 감소시켰다.

[13]은 GAN 학습을 초해상도 영상 복원에 적용하여 저해상도 자동차 번호판 영상을 복원하는 방법을 제안하였다. 실험은 가상으로 생성된 번호판을 이용하여 신경망 학습을 시행하였다. [13]은 실제 교통 동영상에서 이동 차량의 차량 번호판의 화질을 향상시키기 위한 새로운 방법을 제안한다. 번호판의 고해상도 이미지는 여러 개의 하위 픽셀이 시프트된 저해상도 이미지로부터 수집한 정보를 융합하여 얻었

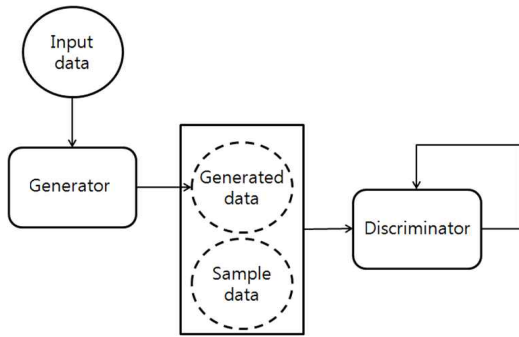


Fig. 1. Conceptual architecture of GAN.

다. [14]에서는 GAN을 이용한 초해상도 기법을 제안하여 자동차 번호판 영상에 최적화되도록 모델을 구성하였다. 실험 결과 실제 번호판 영상을 이용했을 경우 저해상도 영상 인식률이 52.8%에서 88.3%로 향상되었음을 확인하였다. 본 논문은 [13~15]처럼 실제 CCTV 데이터를 SRGAN 기법에 적용하여 화질을 개선하는 실험을 진행하였다.

3. SRGAN 기반의 영상 화질 개선 기법

3.1 GAN(Generative Adversarial Networks)

GAN은 여러 층의 신경망으로 이루어진 생성자(Generator)와 구별자(Discriminator)로 구성되며 대략적인 과정은 Fig. 1과 같다. 생성자는 실제 입력 데이터와 최대한 비슷하게 데이터를 생성해내는 것을 목표로 하고 있다. 반면에 구별자는 생성되어진 데이터와 실제의 샘플 데이터를 최대한 옳게 구분하

려는 것이 목표이다. 따라서 생성자는 구별자가 구분하기 어려울 정도로 높은 품질의 이미지를 생성해야 목표를 달성할 수 있다. 이렇게 생성자와 구별자가 대립(Adversarial)하며 성능을 개선시켜나가는 것이 GAN의 개념이다.

GAN의 목적함수를 식으로 표현하면 식 (1)과 같다.

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

$\arg \max D(\text{Discriminator})$ 와 $\arg \min G(\text{Generator})$ 를 찾는 것을 의미한다. 우선 D는 구별자로 목적함수를 극대화하는 분류 신경망이다. 공식의 첫 번째 항인 $E[\log D(x)]$ 는 실제 데이터 x를 의미하며 실제 목적함수의 값을 의미한다. 두 번째 항 $E[\log(1 - D(G(z)))]$ 는 생성자가 생성한 데이터를 의미한다. 실제 이미지를 입력받으면 큰 값을, 생성 이미지를 입력받으면 작은 값으로 학습한다.

다음으로 G는 목적함수를 극소화하는 생성 신경망이다. G는 두 번째 항인 $E[\log(1 - D(G(z)))]$ 에 포함되어 있다. 전체 함수 값을 극소화함과 동시에 $D(G(z))$ 를 극대화하는 G값을 찾는다. 결과적으로 이 두 항의 목적함수를 이용해 구별자 D를 학습시킨다.

3.2 영상 화질 개선 기법 모델 흐름도

본 논문에서 인용하는 SRGAN 기법의 과정을 Fig. 2로 나타냈다. Generator network는 생성자를 의미하고 Discriminator는 구분자를 의미한다. 우선 생성




Fig. 2. Flow diagram of Generator and Discriminator of SRGAN.

자의 과정을 살펴보면 입력 데이터를 적용하여 컨볼루션을 거치게 된다. 신경망은 입력받은 데이터를 픽셀단위로 분석하여 서로 관련이 높은 픽셀의 특징을 추출하여 인공신경망에 적용한다. 즉 입력받은 이미지 사이에서 위치가 비슷한 데이터들을 컨볼루션 한다[5].

BN(Batch Normalization)은 인공신경망에서 역전파(Back Propagation)를 이용하여 학습을 수행한다. 인공신경망에 포함된 레이어가 깊을수록 역전파 진행 시 전달되는 Gradient 값이 0으로 수렴하거나 발산해서 전체 신경망이 학습되지 않는 기울기 감소(Gradient Vanishing) 혹은 기울기 값 발산(Gradient Exploding)이 발생한다. 따라서 이를 해결하고 전체적인 학습 속도 향상을 위하여 각 레이어에 입력되는 입력 값을 정규화하여 해당 문제 발생 빈도를 줄이는 기법인 BN을 SRGAN에 사용한다.

ReLU는 인공신경망에 사용되는 활성화함수이다. 활성화함수는 인공신경망 노드 값의 계산 결과가 일정 임계점을 넘는지 판단하는 것이 목적이다. 기존에는 Sigmoid나 탄젠트 함수가 사용되었으나 심층 신경망(Deep Neural Network)에 포함된 레이어가 많아지면서 -1에서 1 혹은 0에서 1 사이의 값을 나타내는 함수로는 기울기 값의 소실을 막을 수 없게 되었다. 따라서 임계 값 이후에 큰 값을 결과로 출력하는 ReLU를 추가적으로 사용하여 보완하였다. ReLU는 임계 값 이전에는 0을 출력하며 임계 값 이후에는 입력 값을 그대로 출력하는 활성화함수이다. Dense Layer는 인공신경망에서 이전 계층의 모든 뉴런과 결합되어 있는 형태의 layer를 의미한다. Leaky ReLU는 ReLU 함수의 변형으로 음수에 대해 1/10로 값을 줄여서 사용하는 함수이다.

3.3 기계학습을 위한 데이터 전처리 과정

영상 화질 개선 기법을 구현하기 위하여 CCTV를 통하여 수집한 영상을 이용하였다. 영상은 2017년 8월 1일부터 2017년 8월 31일까지 수집된 영상 데이터이며, 화질은 720P이고 FPS는 30이다. 영상은 4종류이며 프레임단위로 분할하여 각 10,000장의 이미지를 생성하였다. 실제 CCTV를 통하여 획득한 총 40,000장의 이미지를 이용하여 학습 및 검증에 사용할 저화질 이미지를 생성하였다. 저화질 이미지는 원본 고화질 이미지의 1/3 크기로 원본 이미지에서 일정 비율

의 픽셀을 추출하여 저화질 이미지를 구성하였다.

3.4 SRGAN 과정

SRGAN의 목적은 입력받은 낮은 해상도의 이미지에서 높은 해상도의 이미지를 생성하는 것이다. 이를 위하여 SRGAN의 인공 신경망을 학습시켜야 한다. 학습은 생성자 신경망과 구별자 신경망을 연결한 하나의 망으로 진행한다. 구별자 신경망에서 원본 HR 이미지와 생성된 SR 이미지를 비교하고 판단하며 학습을 진행한다. 학습에는 구별자 신경망의 마지막에 포함된 sigmoid 함수를 제거하고 loss function을 계산한다. 구별자 신경망에서 계산된 adversarial loss 값과 독립적인 VGG에서 생성된 content loss 값을 일정비율로 더하여 최종적인 loss 값을 계산한다. SRGAN의 생성자 공식과 구별자 공식은 각각 식 (2)와 식 (3)이다[5].

$$\hat{\theta}_G = \operatorname{argmin}_{\theta_G} \frac{1}{N} \sum_{n=1}^N l^{SR}(G_{\theta_G}(I_n^{LR}), I_n^{HR}) \quad (2)$$

$$\min_{\theta_G} \max_{\theta_D} E_{I^{HR} \sim P_{\text{real}}(I^{HR})} [\log D_{\theta_D}(I^{HR})] + E_{I^{LR} \sim P_G(I^{LR})} [\log(1 - D_{\theta_D}(G_{\theta_G}(I^{LR})))] \quad (3)$$

위 식에서 G는 저화질의 이미지(LR)를 입력받아 고화질의 이미지(SR)를 결과로 생성해 내는 생성자를 의미한다. θ_G 는 G의 파라미터 값이며 l^{SR} 은 원본 이미지(HR)와 비교하여 결정한 loss 함수 값을 의미한다. D는 생성된 이미지를 원본 이미지(HR)인지 생성한 이미지(SR)인지 구분하는 구분자를 의미한다. θ_D 는 D의 파라미터 값이다.

4. 실험 방법 및 결과

실험 당시 수집한 CCTV 데이터는 24시간 녹화되었으며 30일 분량의 영상 데이터이다. 화질은 720P이며 30FPS 속도를 가진 영상 데이터이다. CCTV 녹화 영상은 개인정보 보호법을 위반하지 않고 정당한 방법으로 수집되었으며 데이터 사용으로 동의를 구했다. 총 4대의 카메라를 활용하여 녹화를 진행하여 총 4개의 영상 데이터로 분류했으며 각각 Ch.1, Ch.2, Ch.3, Ch.4라고 명명했다. 그리고 각 영상 데이터는 10,000개의 이미지로 분할 샘플링하여 기계학습에 사용되었다. 40,000장의 이미지에서 90%는 학습에 사용하고 10%는 테스트에 사용하였다.

Table 1. Experimental environment

CPU	INTEL(R) Core(TM) i7-7700
HDD	2 TB
RAM	32 GB
GRAPHIC	NVIDIA GeForce GTX 1060 6GB
OS	Window 10

4.1 성능 평가

실험에 들어가기에 앞서 제안된 기법이 평균적으로 어느 정도의 처리량을 보이는지 살펴본다. 이를 평가하기 위해 제안된 기법이 이미지 10장의 화질 개선 과정을 진행하는 동안 걸리는 시간을 측정하였다. 실험에 사용된 PC의 성능은 Table 1과 같다.

Fig. 3과 같이 총 10회의 실험 측정 결과 제안하는 기법이 10장의 이미지의 화질 개선 과정을 거치기 위해 소요된 시간은 ch.1~ch.4 차례로 각각 5.5분,




Fig. 3. Time measurement of image quality improvement method.

2.8분, 7.2분, 2.1분이었다. ch.3과 ch.4가 상대적으로 작은 이유는 CCTV 영상에서 움직임이 거의 없기 때문에 픽셀의 변화가 크지 않기 때문이다. ch.4는 거의 움직임이 없기 때문에 보다 더 적은 시간이 소요

	Input	Output
ch.1		
ch.2		
ch.3		
ch.4		

Fig. 4. Comparison between input and output of image quality improvement method(ch.1~ch.4).

되었다.

4.2 CCTV 영상 화질 개선 실험 결과

Fig. 4는 본 논문에서 제시한 영상 화질 개선 기법을 적용하기 전의 영상과 적용한 후의 영상의 캡처들을 비교해놓은 것이다. input은 입력 데이터로 사용된 기법이 적용되기 전의 영상이며 output은 영상 화질 개선 기법을 거친 후 출력된 결과 영상이다. ch.1, ch.3은 실내에서 녹화되고 있는 CCTV 영상이며 사람의 유동성이 높은 위치에 설치되어 있다. ch.2와 ch.4는 야외에 설치되어 있는 CCTV 영상이며 특히 ch.4는 상대적으로 사람의 유동성이 적다.

ch.1의 input에는 총 3명의 사람이 있는 것을 분명히 확인할 수 있으나 얼굴을 자세하게 확인할 수 없는 상태이다. 또한 배경에 있는 사물들의 형태가 흐리게 보이고 있다. 그러나 영상 화질 기법을 적용한 후의 결과물인 output을 보면 보다 얼굴의 형태가 뚜렷해짐을 확인할 수 있다. 배경에 있는 사물들도 선명해진 것을 확인할 수 있다. ch.2의 Input은 야외에 사람이 서있는 것을 확인할 수 있으나 화질이 흐려 정확히 몇 명이 있는지 확인이 어렵다. 반면에 output을 보면 정확히 3명이 모여 있는 것을 확실하게 확인할 수 있다. ch.3의 Input도 ch.1의 input과 비슷하게 사람의 수는 정확히 확인가능 하지만 얼굴이 흐릿하게 보인다. 그러나 영상 화질 개선 기법을 거친 후 output을 보면 얼굴이 좀 더 선명해진 것을 알 수 있다. 마지막 영상인 ch.4는 사물들의 형태가 기존보다 뚜렷해진 것을 확인할 수 있다.

Fig. 5와 Fig. 6은 각각 ch.1과 ch.3 영상 중 얼굴부분을 확대한 이미지이다. 화질 개선 기법을 적용하기 전보다 이목구비나 헤어스타일을 포함한 인상착의가 선명하게 보이는 것을 확인할 수 있다. 이러한 화질 개선 기법의 효과는 CCTV 영상을 분석하여 정



Fig. 5. Face expansion of ch.1's input and output.

한 인상착의가 필요할 때 유용하게 사용될 수 있다.

Fig. 7은 ch.2 영상의 사람들이 있는 부분을 확대한 이미지이다. 기법이 적용되기 전에는 사람들 사이에 무엇이 있는지 제대로 구분하기 어렵다. 또한 화면이 흐리기 때문에 몇 명의 사람이 있는지도 선명하게 보이지 않는다. 화질 개선 기법이 적용된 이후에도 얼굴을 정확하게 구분할 정도의 고화질은 아니다. 그러나 CCTV를 통해 사건이 발생하던 상황을 판단하는 근거로 활용하는 것에 도움을 줄 수 있다.

5. 결 론

본 논문에서는 SRGAN을 활용하여 CCTV 영상의 화질을 개선시키는 기법을 제안하고 실험을 진행하였다. 실험 결과 SRGAN을 사용하여 저화질 CCTV 영상 화질을 보다 선명하게 개선하는 것이 가능함을



Fig. 6. Face expansion of ch.3's input and output.



Fig. 7. Face expansion of ch.2's input and output.

보였다. 이는 제안하는 기법이 실생활에서 활용될 수 있음을 의미한다. 즉, 범죄나 재난 예방에 활용될 수 있으며, 오래된 영상 복구에도 사용될 수 있다. 또한 특징점 분석과 같이 CCTV 영상을 기반으로 하는 연구에도 보다 정확한 영상 데이터를 제공함으로써 도움을 줄 수 있다.

향후 연구 과제로는 데이터 전처리 과정이 보다 간단하게 이루어질 수 있도록 기법을 개선하는 것이 필요하다. 또한 본 논문에서 제안한 기법의 프로세싱 속도를 높일 수 있도록 보완하여 실시간으로 화질을 개선되는 방안을 연구하는 것이 향후 과제가 될 수 있다. 한편 제안한 기법의 외부적인 한계점으로 컴퓨터가 고성능이 아니라면 기법을 적용하기 어렵다는 점을 들 수 있다. 기계 학습을 시키기 위한 전처리 과정이 수작업으로 진행된다는 점이 보완해야 할 부분이다.

REFERENCE

- [1] Y.K. Kwak and T.H. Lim, "A Study on the CCTV Effective Utilization Method for the Crime Prevention and Action," *Journal of Korean Association for Public Security Administration*, Vol. 8, No. 2, pp. 119-144, 2011.
- [2] S.M. Rho, "Artificial Intelligence Technology R&D Trend by Patent Analysis," *Journal of Digital Contents Society*, Vol. 18, No. 2, pp. 423-428, 2017.
- [3] J.H. Lee and J.S. Yoo, "Generative Adversarial Nets Analysis and Applications," *Proceeding of the Korean Society of Broadcast Engineers Conference*, pp. 36-39, 2017.
- [4] M.S. Ko, H.G. Roh, and K.H. Lee, "GAN-MOOK: Generative Adversarial Network to Stylize Images Like Ink Wash Painting," *Proceeding of the Korea Institute of Information Scientists and Engineers*, pp. 793-795, 2017.
- [5] C. Ledig, L. Theis, F. Huszár, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, and Z. Wang, "Photo-realistic Single Image Super-resolution Using a Generative Adversarial Network," *arXiv Preprint arXiv:1609.04802*, 2016.
- [6] J.W. Shin, Y.S. Noh, and S.Y. Park, "Generating Multi-Class Images Using a Generative Adversarial Network," *Proceeding of the Korea Institute of Information Scientists and Engineers*, pp. 811-813, 2017.
- [7] S.J. Hong, S.K. Lee, and S.I. Yang, "An Oversampling Technique Based on Generative Adversarial Network for Solving Imbalance Problem of Game Dataset," *Proceeding of the Institute of Electronics Engineers of Korea*, pp. 1227-1228, 2017.
- [8] J. Jeon and M.C. Kim, "Generative Adversarial Network Based CNN Model for Artifact Reduction on HEVC-encoded Video," *Proceeding of The Korean Society of Broadcast Engineers*, pp. 192-193, 2017.
- [9] I. 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.
- [10] S.B. Lee, H.G. Kim, K.S. Shin, and J.H. Nang, "Performance Analysis of Convolution Neural Network and Generative Adversarial Network for Super Resolution," *Proceeding of The Korean Society of Broadcast Engineers*, pp. 931-933, 2017.
- [11] J.W. Kim, J.K. Lee, and K.M. Lee, "Accurate Image Super-resolution Using Very Deep Convolutional Networks," *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1646-1654, 2016.
- [12] D.H. Lee, H.S. Lee, K.J. Lee, and H.J. Lee, "Fast Very Deep Convolutional Neural Network with Deconvolution for Super-Resolution," *Journal of Korea Multimedia Society*, Vol. 20, No. 11, pp. 1750-1758, 2017.
- [13] J.M. Choi and D.J. Kang, "Super-resolution for License Plate Using Generative Adversarial Networks," *Proceeding of Institute of Control Robotics and Systems*, pp. 262-263,

2017.

- [14] J.M. Choi and D.J. Kang, "Deep Super-resolution Method via Generative Adversarial Networks for License Plate Image Enhancement," *Journal of Institute of Control Robotics and Systems*, Vol. 29, No. 8, pp. 635-643, 2017.
- [15] K.V. Suresh, G.M. Kumar, and A.N. Rajagopalan, "Super-resolution of License Plates in Real Traffic Videos," *IEEE Transactions on Intelligent Transportation Systems*, Vol. 8, No. 2, pp. 321-331, 2007.



하 현 수

2016년 가톨릭대학교 컴퓨터정보
공학부 학사
2018년 가톨릭대학교 컴퓨터공학
과 석사
관심분야 : 소셜네트워크분석, 데
이터베이스, 데이터마이
닝, 정보검색



황 병 연

1986년 서울대학교 컴퓨터공학과
학사
1989년 KAIST 전산학과 석사
1994년 KAIST 전산학과 박사
1994년~현재 가톨릭대학교 컴퓨
터정보공학부 교수

1999년~2000년 (美) 미네소타대학교 방문교수
2007년~2008년 (美) 캘리포니아주립대학교 방문교수
관심분야 : 데이터베이스, 정보검색, 소셜네트워크분석