

## Perceptual Generative Adversarial Network for Single Image De-Snowing

Weiguo Wan<sup>\*</sup> · Hyo Jong Lee<sup>††</sup>

### ABSTRACT

Image de-snowing aims at eliminating the negative influence by snow particles and improving scene understanding in images. In this paper, a perceptual generative adversarial network based a single image snow removal method is proposed. The residual U-Net is designed as a generator to generate the snow free image. In order to handle various sizes of snow particles, the inception module with different filter kernels is adopted to extract multiple resolution features of the input snow image. Except the adversarial loss, the perceptual loss and total variation loss are employed to improve the quality of the resulted image. Experimental results indicate that our method can obtain excellent performance both on synthetic and realistic snow images in terms of visual observation and commonly used visual quality indices.

**Keywords :** Generative Adversarial Network, De-Snowing, U-Net, Image Synthesis, Residual Block

## 단일 영상에서 눈송이 제거를 위한 지각적 GAN

Weiguo Wan<sup>\*</sup> · 이 효 종<sup>††</sup>

### 요 약

눈이 내리는 영상에서 눈송이들에 의하여 영상의 질이 저하되고 영상 내에 존재하는 객체들을 명확히 탐지하기 위해서는 눈송이를 제거해야 할 필요성이 있다. 이 연구에서는 지각 Generative Adversarial Network에 기반하여 단일 영상으로부터 눈송이를 제거하는 방법을 제시한다. 전류 U-Net을 눈송이가 제거된 영상을 생성하는 생성기로 설계하였다. 다양한 크기의 눈송이를 처리하기 위하여 다양한 필터 커널의 인셉션 모듈을 설계하고 입력한 눈이 내리는 영상의 다양한 해상도 특징을 추출하기 위하여 적용되었다. 눈송이 제거 영상의 품질을 높이기 위해서 대립순실을 제외하고는, 지각적 순실과 총 변동 순실 합수를 적용하여 제설 이미지와의 유사도를 찾아갈 수 있도록 하였다. 합성 강설 이미지와 실제 강설 이미지를 대상으로 제안 네트워크의 제설 기능을 실험하였다. 실험 결과 제안 알고리즘은 합성 이미지와 강설 이미지 모든 분야에서 육안으로 관찰해본 결과 화질이 우수함을 보여주었고, 객관적 평가를 위하여 신호강도를 나타내는 PSNR과 구조변화를 측정하는 SSIM 인덱스를 비교하였으며, 제안 알고리즘이 지수 상으로도 가장 우수한 성능을 보여주었다.

**키워드 :** GAN, 눈송이 제거, U-net, 영상의 합성, 잔차 블록

### 1. 서 론

악천후 발생 시 지능형 감시 시스템이 교란되고 제대로 기능을 하지 못하여 발생할 수 있는 위험에 대한 적절한 경고를 놓칠 수 있는 경우가 발생된다[1]. 여러 컴퓨터 비전 응용 프로그램들은 강우, 안개 또는 강설과 같은 대기 현상이 발생

할 때 그 기능을 발휘하지 못하는 경우가 많다[2]. Fig. 1은 ImageAI[3]가 객체를 탐지하는 예를 보여주고 있다. 위 그림에서 눈송이들 때문에 객체들을 탐지하는데 방해가 되고 있으나, 눈송이들을 제거한 후에 더 많은 객체가 탐지되는 것을 하단 그림에서 볼 수 있다.

최근 몇 년 동안 대기 입자들로 인한 영상의 저하를 막기 위하여 다양한 대기 입자 제거 방법이 시도되었다. 보편적인 주제로 영상에서 안개나 빗방울 입자를 제거하는 연구가 초기에 시도 되었다. 안개 입자의 제거 방법은 안개 입자가 이미지 위에 균일하게 축적된다는 사실에[4] 착안하여 영상의 특징을 학습시키고 대기의 감쇠현상을 가정하여 개발 되었다. 빗방울 입자의 제거는 빗방울의 모양, 패턴 또는 경계선의 방향성과 같은 일반적인 특징을 모델링하여 시도되었다[5]. 오

\* 이 논문은 2018년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업입니다.(No. 2018R1D1A3B03931911).

\*\* 이 논문은 2019년도 한국정보처리학회 출판학술발표대회에서 '이미지의 눈 제거를 위한 심층 Resnet'의 제목으로 발표된 논문을 확장한 것임.

† 준 회 원: 전북대학교 컴퓨터공학부 박사과정  
†† 종신회원: 전북대학교 컴퓨터공학부 교수

Manuscript Received : July 5, 2019

First Revision : July 26, 2019

Accepted : August 18, 2019

\* Corresponding Author: Hyo Jong Lee(hlee@chonbuk.ac.kr)



Fig. 1. Object Detection on Realistic Winter Snowy Image (Top) and a Corresponding Snow Removal Image of the Proposed Method (Bottom) by Imageai Library

늘날 심층학습기반을 이용하는 방법들은 이전 전통 알고리즘 기반의 방법들보다 일반화 기능이 우수하다는 특성 때문에 광범위한 주목을 받고 있다.

심층학습기반의 빗방울이나 안개 제거 기법들이 입자들의 위치를 파악하여 제거할 수 있어도, 그런 방법들을 눈송이의 제거에 직접 적용하기는 어렵다. 눈송이들이 가지고 있는 불균일한 분포성, 다양한 크기, 불규칙적인 하강 궤적 및 투명한 특징들은 빗방울과는 다른 방법을 요구한다. 따라서 눈송이 제거는 달성하기가 어려우며 새로운 심층학습 기법의 설계가 요구된다. 이미 발표된 눈송이 제거 방법들은 주로 전통 영상처리에서 다른 빗방울이나 안개제거 알고리즘의 특징들에 초점을 맞추어 진행하였기 때문에 일반화를 하는데 매우 취약하다[6].

본 논문에서는 단일 이미지에서 눈송이를 제거하기 위한 새로운 지각적 GAN (generative adversarial network) 프레

임워크를 설계하였다. 생성자는 U-net[7] 아키텍처와 인셉션 모듈(inception module)에 기반하여 구축하였다. 또한 눈송이 제거의 성능을 향상시키기 위하여 지각적 손실과 총변동 손실 함수를 제시하였다. 실험결과는 제안된 방법이 합성 영상과 실제 눈 영상 전체에서 다른 알고리즘들과 비교하여 우수한 성능을 갖는 것을 보여주었다.

본 논문의 이후 구성은 다음과 같다. GAN 네트워크의 간단한 소개를 2절에서 설명하였다. 3절에서는 눈송이 제거를 위한 새로운 제안 방법을 자세히 설명하였다. 4절에서는 합성 영상과 실제 영상을 대상으로 한 실험결과를 비교 설명하고, 마지막으로 토론 및 결론을 5절에 기술하였다.

## 2. Generative Adversarial Network

사실적인 이미지를 생성하기 위하여 2014년 Goodfellow 등[8]은 GAN 심충망을 제안했는데, 생성자 네트워크 G와 구분자 네트워크 D로 구성되었다. 생성자 네트워크는 입력 영상에 기반하여 새로운 이미지를 생성하고, 구분자 네트워크는 그 영상이 참된 영상인지 거짓 영상인지를 구분하였다. GAN 망의 목적은 다음과 같이 표현할 수 있다.

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

Equation (1)에서 x는 분포함수  $p_{data}(x)$ 의 수집된 실제 데이터, z는 잠재 공간변수,  $G(z)$ 는 구분자를 속일 수 있는 가장 높은  $D(x)$  값으로 생성된 데이터를 의미한다.

최근들어 GAN은 학계에서 점점 더 큰 주목을 받고 있다. 이미지 인페인팅(가려진 이미지 복원), 스타일 변형, 텍스처 합성 및 고해상 이미지변형 등과 같은 다양한 이미지-이미지 변형에 적용되어 우수한 성과를 보여주고 있기 때문이다.

## 3. 눈송이 제거 방법

본 절에서는 Fig. 2에 나타난 바와 같이 눈송이 제거를 위한 전체적인 구조에 대한 설명을 하였다. 생성자 네트워크에

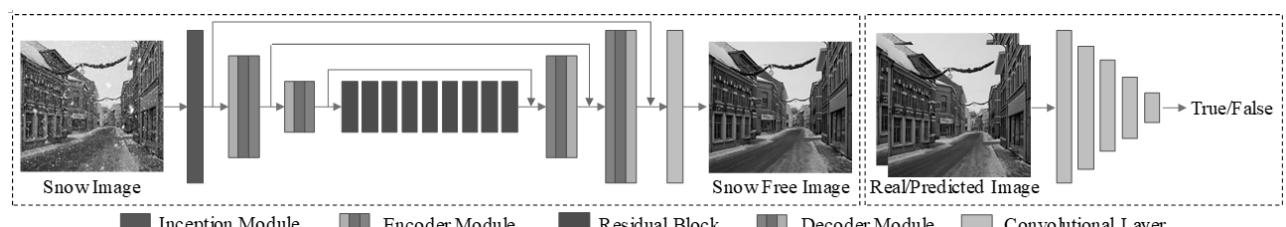


Fig. 2. The Overall Architecture of the Proposed Snow Removal Method. Left Block is the Generator Network Which is Fed with a Snow Image and Predicts a Snow-Free Image, and Right One is the Discriminator Network Which Distinguish the Snow-Free Image is True or Not

Table 1. The Architecture of Generator Network. “Conv” and “Deconv” Denote Convolution and Deconvolution, Respectively

	Block	Inception				Encoder		Residual (x9)		Decoder		Predictor
Generator	Layter	conv	conv	conv	conv	conv	conv	conv	deconv	deconv	conv	
	Kernel	1×1	3×3	5×5	3×3	3×3	3×3	3×3	3×3	3×3	3×3	
	Stride	1	1	1	1	2	2	1	1	2	2	1
	Channel	32	32	32	64	128	256	256	256	128	64	3

Table 2. The Architecture of Discriminator Network

Discriminator	Layter	conv	conv	conv	conv	conv	conv
	Kernel	3×3	3×3	3×3	3×3	3×3	3×3
	Stride	2	2	2	2	2	2
	Channel	32	64	128	256	256	1

서는 인셉션 모듈을 입력된 강설 이미지의 다중 해상도 특징을 추출하기 위해 먼저 적용한 다음, 스트라이드 2를 적용한 두 개의 컨벌루션 층이 추출된 다중 해상도 특징을 인코딩하는 인코더로 사용되었다. 그 후 9개의 잔차 블록(residual block)을 학습능력을 증가시키기 위하여 인코더와 디코더 사이에 삽입하였다. 디코더 부분에서는 반 크기의 스트라이드를 갖는 디컨벌루션 층이 원래 해상도와 같은 피쳐맵(feature map)으로 해상도를 높이기 위하여 적용되었다. 그 다음, 눈송이가 제거된 이미지를 얻을 수 있는 피쳐맵으로 변환을 할 수 있도록 컨벌루션층을 사용하였다. 구분자 네트워크는 다섯 층의 순수한 CNN (convolution neural network)으로 구성하였다. 생성자와 구분자 망의 구체적인 구조를 Table 1과 Table 2에 요약하였다.

### 3.1 인셉션 모듈 (Inception module)

강설 이미지는 다양한 크기의 눈송이 때문에 다중 해상도 특징값 추출을 위하여 인셉션 모듈[9]을 사용하였다. 인셉션 모듈은 Fig. 3에 그려진 바와 같이 필터 크기를  $1 \times 1$ ,  $3 \times 3$ ,  $5 \times 5$ 로 갖는 3개의 컨벌루션 층으로 특징값을 누적 시킨다. 컨벌루션 층의 각 그룹은 32개의 필터 커널을 갖는다. 그런 후

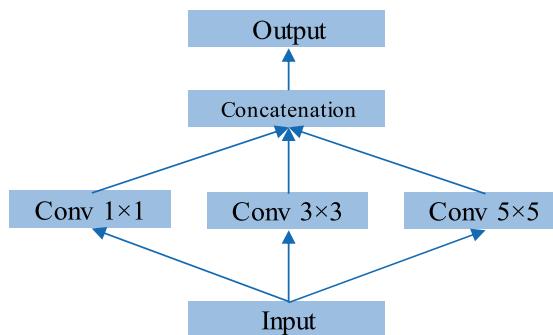


Fig. 3. Structure of an Inception Module

64개의 필터가 있는  $3 \times 3$  컨벌루션 층이 누적된 특징값 상에서 작동하여 인셉션 모듈의 출력을 생성한다.

### 3.2 잔차 블록 (Residual blocks)

최근 잔차 네트워크는 이미지 고해상도화[10], 이미지 선명화[11] 및 벗방울 제거[12] 등과 같은 컴퓨터 비전 영역에서 우수한 성능을 내는 것으로 보고되었다. 잔차 네트워크에서 각 계층은 다음 층으로 입력되고, Fig. 4에 나타낸 바와 같이 여러 층을 건너뛰어 연결되기도 한다. 잔차 네트워크는 심층 네트워크를 통해서 역전파를 계산할 때 기울기 값이 소멸되는 문제를 극복할 수 있다. 본 논문에서는 학습능력을 향상하기 위해서 다중 잔차블럭을 적용하였다. 원래 제안된 잔차 모듈과 달리, 배치 정규화 작업을 인스턴스 정규화 작업으로 대체하여 이미지-이미지 변환 작업에서 더 좋은 결과를 얻을 수 있도록 최적화를 시켰다[13].

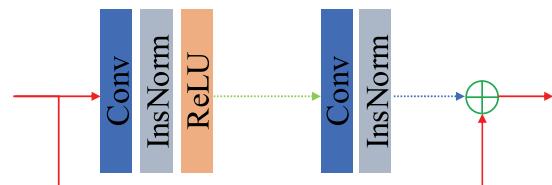


Fig. 4. Architecture of a Residual Block

### 3.3 손실 함수

적절한 손실 함수는 심층망 모델의 성능을 향상시키고 강인한 네트워크로 학습시키는데 필수적이다. 만일  $x$ 와  $y$ 를 학습에 사용하는 강설 이미지와 눈이 내리지 않는 이미지, 즉 제설된 이미지라 정의하고,  $y'$ 를 눈이 제거된 예측 제설 이미지라고 하자. 이 조건에서 제안하는 GAN 모델의 학습을 위해 사용되는 손실 함수의 모델을 설명하고자 한다.

GAN 네트워크에서 대립 손실(adversarial loss)은 특징값

으로 채택된다. 여기에서는 생성자 네트워크의 대립 손실로 최소자승 손실을 적용하였다.

$$L_a = E_{x \sim P_{photo}(x)}[(D(G(x)) - 1)^2] \quad (2)$$

평균자승오차 (MSE) 또는 L2 손실은 일반적인 영상의 복구 작업에서 가장 널리 사용되는 손실 함수이다. 평균자승오차 손실은 아래와 같이 정의될 수 있다.

$$L_M(y, y') = \frac{1}{n} \sum (y - y')^2 \quad (3)$$

Equation (3)에서 n은 각 이미지를 구성하는 화소의 개수이다.

지각 손실 (perceptual loss)[14]은 VGG-19와 같은 심층망에서 상위계층 특징값들을 추출하는데 효율적이라는 것이 최근 들어 증명되었다. 손실함수에 지각 손실을 적용하기 위하여 Equation (4)와 같이 정의하였다.

$$L_P(y, y') = \sum \| \Phi_l(y) - \Phi_l(y') \|_2^2 \quad (4)$$

Equation (4)에서  $\Phi_l$ 은 VGG-19 망에서 l-번째 특징벡터 (feature map)에 해당한다.

예측하는 제설 이미지에서 발생할 수 있는 잡음과 인공물을 없애주기 위하여 추가로 총 변동 손실을 Equation (5)와 같이 정의하였다.

$$L_T(y') = \sum_{m, n} ((y'_{i+1, j} - y'_{i, j})^2 + (y'_{i, j+1} - y'_{i, j})^2) \quad (5)$$

Equation (5)에서  $y'_{i, j}$ 는 예측 제설 이미지의  $(i, j)$  상에 있는 화소값을 의미한다.

생성자를 학습하기 위해 사용되는 총 손실함수는 앞서 정의된 Equation (2)에서 Equation (5)까지의 손실함수에 각각 다른 가중치를 부여하여 Equation (6)과 같이 정의하였다.

$$L_G = \lambda_1 L_a + \lambda_2 L_M + \lambda_3 L_P + \lambda_4 L_T \quad (6)$$

구분자를 위한 손실함수는 예측 제설 이미지  $G(x)$ 와 참된 제설 이미지  $y$ 를 활용하여 Equation (7)과 같이 정의하였다.

$$L_D = \frac{1}{2} E_{z \sim P(z)}[(D(z) - 1)^2] + \frac{1}{2} E_{x \sim P(x)}[D(G(x))^2] \quad (7)$$

## 4. 실험

### 4.1 데이터 수집

본 논문에서는 Snow 100K[15] 데이터를 개발한 눈송이 제거용 심층 네트워크의 학습과 실험에 나누어 사용하였다. 사용 데이터는 100K 장의 합성 강설 이미지와 그에 대응하는 100K 장의 눈이 내리지 않는 이미지, 그리고 1329 장의 야외에서 촬영된 실제 눈이 내리는 영상을 포함시켰다.

입력영상의 종횡비는 통일되지 않아서 정규화를 시킬 필요가 있었다. 따라서 모든 이미지는 종횡비(aspect ratio)를 유지하면서 긴 방향의 크기를 640 화소로 정규화 하였다. 무작위로 10K의 강설 이미지와 정상 이미지 쌍을 선택하여 학습에 사용하였으며, 선택되지 않은 데이터 군에서 무작위로 선택한 2K의 이미지 쌍을 선정하여 시험에 사용하였다. 그리고 실제 강설 이미지는 모두 시험에 사용하여 성능을 검증하였다.

### 4.2 실험 환경

본 절에서는 제안 네트워크를 학습시키는데 필요한 구체적인 변수의 설정과 실험방법을 소개한다. Equation (6)의  $\lambda$  값은 경험에 의하여 우수한 성능을 산출하도록 [ 1, 0.1, 10, 0.0001 ]로 설정하였다. 또한 학습의 반복은 10, 배치작업의 크기는 8로 설정하였다. Adam 최적기는 학습률 0.0001로 설정하여 모든 네트워크 학습에 적용하였다. 실험은 인텔(R) i7, 8GB 메모리와 NVIDIA GTX Titan-X GPU를 이용하여 수행하였다.

### 4.3 실험 결과

제안 방법의 성능을 검증하기 위하여 전통적인 방법[16]과 심층학습기반의 방법[11]을 비교하였다. 공정한 비교를 위하여 강설 이미지를 활용하여 제안하는 심층 학습모델을 동일하게 학습시켰다.

실험은 합성 강설 이미지와 실제 강설 이미지 데이터를 모두 사용하여 진행하였다. 입력 강설 이미지와 예측 제설 이미지의 일부를 Fig. 5와 Fig. 6에 나타내었다.

이미지의 시각적인 비교에 의하면 Zheng 등[16]의 방법은 예측 제설 이미지에서 결과가 잘 나오지 않으며 번짐 현상이 발생되는 것을 볼 수 있다. DeblurGAN[11] 방법의 결과는 여러 곳에서 인공물(artifacts)이 나타나는 것을 볼 수 있다. Fig. 5의 합성 강설 이미지의 결과를 세밀히 관찰해보면 Zheng 등의 방법과 DeblurGAN 방법에서는 동일한 학습을 시켰음에도 불구하고 제안 알고리즘과 달리 눈송이의 영상이 곳곳에 남아있는 것을 알 수 있다. 제안 알고리즘은 최상의 제설 결과를 보여주며 이미지의 세세한 부분까지 그대로 보존하고 있는 것을 볼 수 있다.



Fig. 5. Snow Removal Results of Various Methods for Synthetic Snowy Images. (a) Input Image. (b) Zheng et al. [16].  
(c) DeblurGAN [11]. (d) The Proposed Method, Best Viewed on Screen

Fig. 6의 실제 눈이 오는 이미지를 가지고 실험한 결과를 관찰해보면 DeblurGAN 방법도 눈송이의 제거는 양호하게 이루어지고 있으나 이미지의 번짐 현상이 발생하여 색상의 값이 희미해지고, 건물의 경계선 등이 명확하지 않음을 알 수 있다. Zheng 등의 방법은 번짐현상이 더욱 심각함을 알 수 있다. 제안 알고리즘은 눈송이의 제거도 완전하고 이미지의 화질이 원본 영상과 거의 유사하게 유지되고 있음을 확인 할 수 있다.

육안에 의한 시각적 비교는 관찰자의 주관적인 감성에 영향을 받을 수 있다. 또한 개인적인 선호도에 따라서 이미지의 평가가 다를 수 있다. 따라서 본 연구에서는 이미지의 비교에 사용되는 두 개의 지수, 즉 PSNR과 SSIM을 측정하여 실험 결과 영상의 객관적이며 정량적인 비교 방법을 제시하고자 한다.

PSNR(peak signal-to-noise ratio)은 최대신호대잡음비를 나타내며 신호가 가질 수 있는 최대값에 대한 잡음값의 비율을 계산하는 지수로 화질의 손실정보를 평가할 때 주로

사용된다. PSNR은 주로 평균제곱오차(MSE: mean squared error)를 사용하여 정의할 수 있다.

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [P(i, j) - Q(i, j)]^2 \quad (8)$$

Equation (8)에서 P와 Q는 각각 원래의 이미지와 비교하고자 하는 왜곡된 이미지를 나타내고 있다.

$$\begin{aligned} PSNR &= 10 \log_{10} \left( \frac{MAX_P^2}{MSE} \right) \\ &= 20 \log_{10} \left( \frac{MAX_P}{\sqrt{MSE}} \right) \\ &= 20 \log_{10}(MAX_P) - 10 \log_{10}(MSE) \end{aligned} \quad (9)$$

Equation (9)에 보이는 바와 같이 평균제곱오차가 분모항을 차지하고 있어서, 이 값이 작을 수록 더 큰 최대신호대잡음비를 갖게 되는 것을 볼 수 있다.



Fig. 6. Snow Removal Results of Various Methods for Realistic Snowy Images. (a) Input Image. (b) Zheng et al. [16]. (c) DeblurGAN [11]. (d) The Proposed Method, which are Viewed Best on Screen

신호대잡음비는 사람이 느끼는 주관성을 배제하는 것이 장점일 수도 있으나, 경우에 따라서는 시각적으로 불량한 이미지도 신호대잡음비는 더 크게 나타날 수도 있다는 한계를 지니고 있다. 따라서 이를 보완하기 위하여 구조정보의 왜곡 정도를 나타내는 지수를 사용하며, 이 지수를 구조적 유사지수(structural similarity: SSIM)라고 정의하였다[17].

SSIM은 두 이미지 간의 평균 밝기(L), 콘트라스(C) 및 구조성(S)으로 Equation (10)–(12)를 이용하여 정의된다.

$$L(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (10)$$

$$C(x, y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \quad (11)$$

$$S(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \quad (12)$$

위 식들에서  $\mu$ ,  $\sigma$  및  $\sigma^2$ 는 각각 이미지의 평균값, 분산 및 공분산을 나타내며,  $c_1$ ,  $c_2$  및  $c_3$ 은 각각  $(0.01L_{\max})^2$ ,  $(0.03L_{\max})^2$  및  $c_2 / 2$ 로 정의된다. 여기에서  $L_{\max}$ 는 화소의 최대 밝기를 나타낸다.

Equation (10)–(12)를 적용하여 SSIM은 Equation (13)과

같이 정의된다.

$$SSIM(x, y) = L(x, y)^{\alpha} C(x, y)^{\beta} S(x, y)^{\gamma} \quad (13)$$

Equation (13)에서 상수  $\alpha$ ,  $\beta$ ,  $\gamma$ 는 1로 설정하면 간략한식으로 변형시킬 수 있다.

결과 이미지들의 객관적인 평가를 위하여 입력 영상과 제설 이미지들의 PSNR과 SSIM을 계산하였다. Table 3에 정리된 바와 같이 최대신호대잡음비 (PSNR)와 구조적인 안정성 (SSIM)에서 모두 제안 방법이 가장 성능이 좋은 결과를 보여주고 있다.

Table 3에 나타나는 바와 같이 제안 방법이 기존의 유명방법에 비하여 우수한 성능을 낼 수 있었던 것은 제안 네트워크에 인셉션 모듈을 사용하였기 때문으로 분석된다. DeblurGAN[11]은 일반 CNN 기반의 딥러닝학습을 시킨 반면, 제안 네트워크에서는 눈송이 입자의 다양한 크기를 걸러 낼 수 있도록 인셉션 모듈에서 처리를 하기 때문에 더 우수한 결과를 낼 수 있었다. Table 3에 기록된 평균 예측 시간을 보면 제안 알고리즘이 가장 빠른 시간을 보이고 있는데, 이것은 큰 차이는 아니지만 변수의 크기면에서도 Zheng 등의 방법이나 DeblurGAN보다 작은 메모리를 사용하고 있다고 추정할 수 있다.

Table 3. Objective Comparison of Different Methods

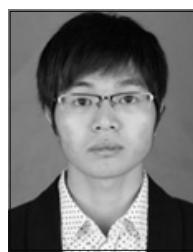
	Synthetic	Zheng et al.[16]	DeblurGAN[11]	Proposed
PSNR	22.179	22.324	23.301	24.631
SSIM	0.825	0.753	0.827	0.846
Time (sec)		2.636	0.165	0.113

## 5. 결 론

본 논문에서 지각 GAN 기반 단일 이미지 제설 방법을 제시하였다. GAN 네트워크에서 생성자는 인셉션 모듈을 사용하여 다중해상도 특징값을 추출하도록 하였다. 또한 지각 손실과 총 변량 손실을 적용하여 설계한 네트워크를 학습하여 네트워크의 종합적인 성능을 향상하였다. 합성 및 실제 강설 이미지를 이용하여 제안 방법의 성능을 측정하였으며, 실험 결과 제안 방법이 육안에 의한 시각적 검사방법과 PSNR과 SSIM 지수를 사용하는 정량적인 방법 모두에서 기준 방법에 비하여 가장 우수한 성능을 보이는 것을 증명하였다. 향후 연구에서는 제안 네트워크를 개선하여 눈송이 이외에도 빛방울이나 안개 입자 등과 같은 다른 대기 입자의 제거를 실험해보고 전반적인 대기 입자를 양호하게 제거할 수 있는 방법을 연구할 수 있을 것이다.

## References

- [1] X. Fu, B. Liang, Y. Huang, X. Ding, and J. Paisley, “Lightweight pyramid networks for image deraining,” *arXiv preprint arXiv: 1805.06173*, 2018.
- [2] L. Deng, T. Huang, X. Zhao, and T. Jiang, “A directional global sparse model for single image rain removal,” *Applied Mathematical Modelling*, Vol.59, pp.662–679, 2018,
- [3] ImageAI [Internet], <http://imageai.org/>.
- [4] R. Li, J. Pan, Z. Li, and J. Tang, “Single image dehazing via conditional generative adversarial network,” in *Proceedings of the CVPR*, pp.8202–8211, 2018.
- [5] W. Yang, R. T. Tan, J. Feng, J. Liu, Z. Guo, and S. Yan, “Deep joint rain detection and removal from a single image,” in *Proceedings of the CVPR*, pp.1357–1366, 2017.
- [6] S. Pei, Y. Tsai, and C. Lee, “Removing rain and snow in a single image using saturation and visibility features,” *IEEE International Conference on Multimedia and Expo Workshops*, pp.1–6, 2014.
- [7] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” *International Conference on Medical Image Computing and Computer-assisted Intervention*, pp.234–241, 2015.
- [8] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, “Generative adversarial nets. in International Conference on Neural Information Processing Systems,” pp.2672–2680, 2014.
- [9] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1–9, 2015;
- [10] Y. Zhang, Y. Tian, Y. Kong, B. Zhong, and Y. Fu, “Residual dense network for image super-resolution,” in *Proceedings of the CVPR*, pp.2472–2481, 2018.
- [11] O. Kupyn, V. Budzan, M. Mykhailych, D. Mishkin, and J. Matas, “Deblurgan: Blind motion deblurring using conditional adversarial networks,” in *Proceedings of CVPR*, pp.8183– 8192, 2018.
- [12] Z. Fan, H. Wu, X. Fu, Y. Huang, and X. Ding, “Residual-guide network for single image deraining,” *2018 ACM Multimedia Conference on Multimedia*, pp.1751–1759, 2018.
- [13] B. Wu, H. Duan, Z. Liu, and G. Sun, “SRPGAN: Perceptual generative adversarial network for single image super resolution. *arXiv preprint arXiv:1712.05927*, 2017.
- [14] J. Johnson, A. Alahi, L. Fei-Fei, “Perceptual losses for real-time style transfer and super-resolution,” *European Conference on Computer Vision*, pp.694–711, 2016.
- [15] Y. F. Liu, D. W. Jaw, S. C. Huang, and J. N. Hwang, “DesnowNet: Context-aware deep network for snow removal,” *IEEE Transactions on Image Processing*, Vol.27, No.6, pp.3064–3073, 2018.
- [16] X. Zheng, Y. Liao, W. Guo, X. Fu, and X. Ding, “Single-image-based rain and snow removal using multi-guided filter,” in *Proc. Int. Conf. Neural Inf. Process*, pp.258–265, 2013.
- [17] Z. Wang, A. C. Bovik, H. Sheikh, and E. Simoncelli, “Image quality assessment: from error visibility to structural similarity,” *IEEE Transactions on Image Processing*, Vol.13, No.4, pp.600–612, 2004.



Weiguo Wan

<https://orcid.org/0000-0002-3537-979X>

e-mail : wanwgplus@gmail.com

2014년 중국 Jiangxi Normal University

수학과(학사)

2016년 중국 Jiangxi University of  
Financial and Economics

정보기술과(석사)

2016년~현 재 전북대학교 컴퓨터공학부 박사과정

관심분야: 영상처리, 컴퓨터비전 및 심층학습



### 이 효 종

<https://orcid.org/0000-0003-2581-5268>

e-mail : hlee@chonbuk.ac.kr

1986년 미국 University of Utah

컴퓨터과학과(학사)

1988년 미국 University of Utah

컴퓨터과학과(석사)

1991년 미국 University of Utah 컴퓨터과학과(박사)

1991년~현재 전북대학교 컴퓨터공학부 교수

관심분야: 영상처리, 패턴인식, 인공지능 및 병렬처리 등