

어두운 환경 감시를 위한 GAN 기반 영상 변환 기법

정성운*¹, 권혁주*², 김영춘**², 안상호***³, 이성학*³

Image Translation Method based on GAN for Surveillance under Dim Surround

Sung-Woon Jung*¹, Hyuk-Ju Kwon*², Young-Choon Kim**², Sang-Ho Ahn***³,
and Sung-Hak Lee*³

이 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단과 2018년 대구광역시 미래형자동차 선도 기술 개발사업의 지원을 받아 수행된 기초연구사업임. (NRF-2019R1D1A3A03020225, DG-2018-03)

요 약

생산적 적대 신경망(generative adversarial network) 학습 기반의 영상 변환은 낮 영상을 밤 영상으로 재생하는 방법 등에 활용될 수 있다. 그러나 어두운 밤 영상을 낮 영상으로 변환하는 반대의 경우, 영상에서 손실된 정보를 예측하여 다시 생성하기 때문에 낮 영상을 밤 영상으로 변환할 때보다 많은 문제를 노출한다. 본 논문에서는 pix2pix 기법을 기반으로 하여 밤 영상을 낮 영상으로 변환하는 방법을 제안한다. 제안한 방법은 기울기 소실(gradient vanishing) 문제를 해결하기 위하여 pix2pix 은닉 유닛 수를 최적화하고 가상의 밤 영상에 대한 학습 데이터를 만들기 위하여 촬영된 낮 영상의 노출 값을 조절하였다. 실험 결과는 제안된 방법이 pix2pix와 Cycle GAN보다 정답 영상(ground truth)과 비교한 MOS(mean opinion score)와 PSNR(peak signal-to-noise ratio) 지표에서 우수한 결과를 보여준다.

Abstract

The GAN(generative adversarial network) learning-based image transformation can be used for conversion from day images to night images. However, in the case of converting from night images to day images, because the lost information in the night image is predicted and recreated, it exposes more problems than when converting day images into night images. In this paper, we proposed a method of converting day images into night images based on pix2pix. The proposed method reduces the number of hidden units in the pix2pix to solve the problem of gradient vanishing and adjusted the exposure value of the captured day image to create training data for the virtual night image. The experimental results show that the proposed method is superior to pix2pix and Cycle GAN in MOS(mean opinion score) and PSNR(Peak Signal-to-Noise Ratio).

Keywords

GAN, hidden unit, laplacian filter, bilateral filter

* 경북대학교 IT대학 전자공학부(교신저자)

- ORCID¹: <https://orcid.org/0000-0002-2258-3396>

- ORCID²: <https://orcid.org/0000-0002-7665-4049>

- ORCID³: <https://orcid.org/0000-0002-1030-381X>

** U1 대학교 정보통신보안학과 교수

- ORCID: <https://orcid.org/0000-0001-7868-501X>

*** 인제대학교 전자 IT기계자동차공학부 교수

- ORCID: <https://orcid.org/0000-0001-7122-662X>

• Received: Jun. 11, 2020, Revised: Jul. 24, 2020, Accepted: Jul. 27, 2020

• Corresponding Author: Sung-Hak Lee

School of Electronics Engineering, Kyungpook National University, 80

Daehak-ro, Buk-gu, Daegu, 41566, Korea

Tel.: +82-53-950-7216, Email: shak2@ee.knu.co.kr

1. 서 론

최근 주목 받고 있는 생산적 적대 신경망(Generative adversarial network)은 영상을 다른 성격의 새로운 영상으로 생성하는 기능을 제공하여 다양한 산업 분야에서 주목 받고 있다[1].

생산적 적대 신경망을 이용하여 영상의 해상도를 높이거나 사람의 얼굴을 바꾸는 어플리케이션도 등장 하고 있고, 대표적으로 생산적 적대 신경망 학습 기반의 pix2pix는 입력 영상과 목표 영상을 변환 학습하는 방식으로 새로운 영상을 생성하는 방법을 보여 주었다[2][3].

예를 들어 경계 영상을 원 영상으로 복원하거나 그림 1과 같은 낮 영상을 밤 영상으로 변환 시키는 방법에 적용될 수 있다. 그러나 pix2pix로 학습시키기 위해서는 학습 영상과 목표 영상이 동일한 장소와 위치에서 촬영이 되어야하기 때문에 현실적으로 다양한 학습 데이터 셋을 취득하기 어렵다. 또한 결과 영상에서 색상을 왜곡 하는 등의 단점을 보여준다. 생산적 적대 신경망으로 생성된 영상은 의도하지 않은 잡음 및 경계 왜곡과 같은 문제가 발생한다[4]. 또한 학습 할 때 많은 양의 학습 데이터와 시간이 필요하다. 본 논문에서는 결과를 도출하는데 필요한 학습 데이터의 수가 17283에서 270으로 줄어들었다.

이러한 특징을 가지고 있는 생산적 적대 신경망을 이용하여 밤 영상을 낮 영상으로 바꾸거나 극히 어두운 영상의 시인성을 개선 한다면 실제 산업 현장에서 손실된 정보를 복구하거나, 보안, 감시의 CCTV 분야에 야간의 어두운 영상이나 실내의 조명 밝기가 어두운 곳을 밝은 영상으로 바꾸는 등에 응용을 할 수 있을 것으로 전망된다.




그림 1. 낮 영상을 밤 영상으로 바꾼 결과[3]
Fig. 1. Result of conversion from day image to night image[3]

본 논문은 생산적 적대 신경망을 기반으로 어두운 영상을 밝은 영상으로 변환하는 알고리즘을 제안하였다. 첫 번째로 pix2pix의 단점을 보완하기 위해 낮과 밤 영상에서 태양과 같은 외광위치에 따른 색상 정보의 손실 및 실제 해당 데이터 셋을 습득하기 어려운 점을 고려하여 영상의 노출 값(EV)에 변화를 주어 데이터 셋을 구성하였다. 다음으로 학습 시 많은 시간과 데이터를 필요로 하는 단점을 개선하고 생성된 영상에서 발생하는 색상 왜곡 문제를 해결하기 위해 은닉 유닛(Hidden unit)의 구조를 최적화 하였다. 이로부터 적은 양의 데이터 셋과 학습량으로 좋은 성능의 결과를 도출 할 수 있다. 마지막으로 생산적 적대 신경망의 잡음 문제를 해결하기 위해 결과 영상에 라플시안(Laplacian) 필터를 사용하여 영상 경계를 강조 하고 바이래터럴(Bilateral) 필터로 국부적 영상 잡음을 제거하였다.

결과적으로 270쌍의 데이터로 학습한 제안된 모듈과 기존의 알고리즘인 Cycle GAN 그리고 pix2pix의 비교 결과에서 PSNR(Peak Signal-to-Noise Ratio)과 MOS(Mean Opinion Score)의 평균값은 각각 Cycle GAN에서 73%와 36%의 더 좋은 효율을 보여 주며 pix2pix에서 52%와 75%의 더 좋은 효율을 보여준다.

II. Background

2.1 생산적 적대 신경망

생산적 적대 신경망은 영상분류 분야에서 널리 알려진 합성곱 신경망 합성곱 신경망(Convolution neural network)을 바탕으로 생성기(Generator)와 판별기(Discriminator)로 구성된다[5][6]. 생성기는 다운 샘플링(Down sampling) 역할을 하는 인코더(Encoder)와 업 샘플링(Up sampling) 역할을 하는 디코더(Decoder)로 이루어진 오토 인코더(Auto-encoder)로 구성되어 가짜 영상을 생성한다[7]. 그리고 판별기는 생성기에서 생성된 결과물과 변환하고자 하는 목표 영상을 판별하는 역할을 한다.

생산적 적대 신경망의 목표는 생성기의 손실을 줄이고 판별기의 손실을 증가시키는 것이다. 판별기

가 생성기의 성능을 압도하기 때문에 생성기의 손실을 줄이기 위해서는 판별기의 성능을 고정 시켜야한다. 그러나 생산적 적대 신경망은 비지도 학습(Unsupervised learning)의 형태를 가지고 있기 때문에 정확한 결과를 예측 할 수 없는 문제점을 가지고 있다.

2.2 이미지 대 이미지 변환(Image to Image Translation)

이미지 대 이미지 변환 방법인 pix2pix는 변환하고자 하는 학습 영상과 학습 목표 영상을 입력으로 사용한다. 학습 영상과 목표 영상은 동일한 장소에서 촬영이 되어야하며 두 영상은 밤과 낮 또는 계절과 같은 차이만 존재해야 한다[3].

밤낮(night2day) 데이터 셋에서는 낮 영상을 밤 영상으로 변환하는데 사용하였다. 데이터 셋은 17,823장으로 밤낮 영상 쌍으로 구성되어있으며 전체 영상 사이즈는 256×512이고 낮과 밤 영상은 너비가 절반인 각각 256×256 이다. 또한 데이터 셋은 밝은 낮 영상과 시간에 따른 저녁 영상으로 구성되어있다. 실제로 이 데이터 셋을 이용하여 학습 방향을 반대로 하여서 밤 영상을 낮 영상으로 바꾸기 위해 학습할 경우 결과영상의 경계와 색 성분이 왜곡되는 등의 문제를 보인다.

III. 제안하는 방법

본 논문에서는 어두운 촬영 환경의 영상을 밝은 환경의 영상으로 변환하는 알고리즘을 제안한다. 그림 2는 제안하는 알고리즘의 구성을 나타낸다. pix2pix에서 실제 데이터를 얻기가 매우 힘들기 때문에 그림 2의 입력 층(Input layer)에서와 같이 노출 값을 변경한 가상의 데이터 셋을 사용하였다. 전체적인 흐름은 생산적 적대 신경망을 기반으로 된 pix2pix와 유사하지만 은닉 유닛에서 계층의 최적화를 통해 기존 방식의 문제점인 기울기 소실(Gradient vanishing) 문제로 인한 색상 왜곡을 해결하고 생성된 영상에서 발생하는 잡음과 경계 왜곡을 개선하기 위한 후처리 알고리즘을 추가 하였다.

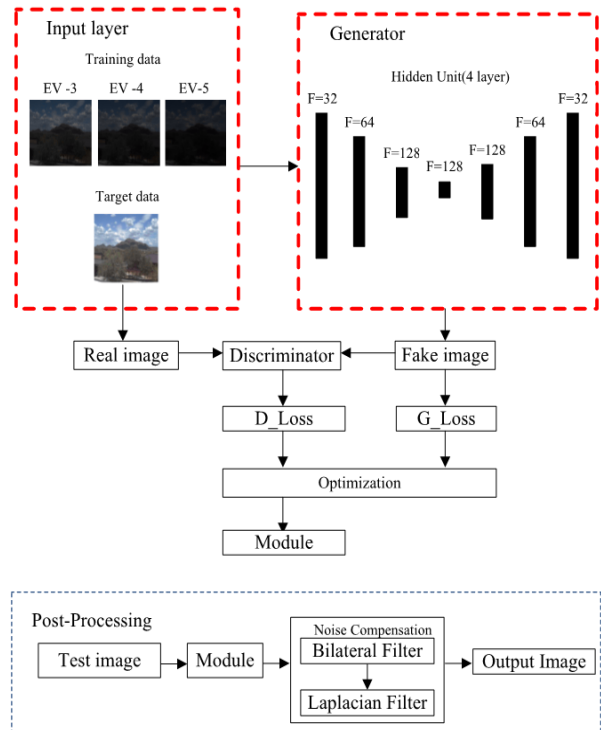


그림 2. 제안 방법 흐름도
Fig. 2. Flowchart of proposed method

3.1 가상 학습 데이터 셋 구성

기존 데이터 셋 구성은 시간에 따른 밤 영상과 낮 영상으로 구성 되어있다. 실제로 이와 같은 데이터를 획득하기는 매우 어렵기 때문에 가상의 학습 데이터 셋을 구성하였다. 어두운 영상을 밝은 영상으로 변환 하는 학습을 위한 데이터 셋 구성은 그림 3과 같다. 밝은 영상과 가상의 어두운 영상의 쌍으로 구성되며 어두운 영상은 다양한 상황을 구현하기 위해 밝은 영상의 EV(노출 값)를 -3, -4, -5로 낮추어 생성되었다[8]. 기존 방식에서의 어두운 영상은 색 정보가 없거나 태양(혹은 조명)의 위치에 따라 색 정보가 변하는 반면 제안된 데이터 셋은 낮은 EV에서도 색 정보의 변화가 기존 방식보다 적다. 이러한 데이터 셋 생성은 실제 실험을 통해 실제 밤 영상을 쓰는 것보다 더 효율적임이 확인된다. 특히 태양과 같은 외광의 영향을 적게 받는 실내 영상에서 차이가 두드러진다. 생성된 영상에서 기존 방식은 실내사진에서 밝기만 조금만 증가 할 뿐이지만 제안 방법은 조명을 켜올 때와 유사한 결과를 보였다.



(a) EV -3



(b) EV -4



(c) EV -5

그림 3. 학습 데이터 셋
Fig. 3. Learning data sets

3.2 학습 계층의 최적화 및 후처리

기존의 학습 방법은 7개의 고정된 은닉 유닛의 계층으로 구성 되어 있다. 그러나 많은 은닉 유닛의 계층은 계산량을 증가시키고 기울기 소실 현상이 일어나기 때문에 학습의 최적화를 위해서 학습 계층을 최적화 할 필요가 있다. 이를 위해 학습 계층을 정할 때는 식 (1)의 연산시간 조건을 고려하였다.

$$TL_c = NF \times NP \times TF \quad (1)$$

$$NP_H = \frac{H - 2P - F_H}{S} + 1 \quad (2)$$

$$NP_W = \frac{W - 2P - F_W}{S} + 1 \quad (3)$$

여기서 TL_c 은 각 계층에서 연산 시간, NF 는 전체 특징 맵(Feature map)의 수, NP 는 출력 픽셀의 수

이며 TF 는 각 필터의 연산 시간이다. 첨자 H 와 W 는 각 높이와 너비를 나타낸다. F 는 필터의 크기를 나타낸다. P 와 S 는 각각 패딩(Padding)과 스트라이드(Stride)의 크기이다.

Pix2pix에서는 생성기 손실 값이 최저가 되는 때가 학습이 종료되는 시점이다. 그러나 손실 값이 최저가 되어도 pix2pix의 결과 영상은 색이 왜곡되는 현상이 관찰된다. 이는 기울기 소실 문제로 데이터 량과 계층의 양에 의한 학습량이 너무 과도한 것이 원인이다. 문제를 해결하기 위해서는 학습량을 줄이는 방법으로 $NF = 64$ 를 $NF = 32$ 로 수정하였다. $TF \propto NF$ 이므로 TL_c 가 줄어들어 기울기 소실 문제가 완화되며, 이는 연산 조건식 (1)~(3)에 맞게 $S = 2$ 에서 $S = 4$ 로 조절하여야 한다.

표 1은 식 (1)~(3)의 주요 수치들을 나타낸다. 기존은 NP 가 마지막 은닉 유닛을 통과할 때의 과정에서 1×1 이며 이 때 $NF = 512$ 이므로 총 특징의 매개 변수는 512이다. 또한 제안 방법의 마지막 은닉 유닛을 통과 할 때는 NP 가 2×2 에 NF 가 128이므로 마지막 총 특징의 매개 변수는 기존 방법의 값과 동일하게 유지 된다.

표 1. 최적화를 위한 방법별 출력 픽셀 값과 특징 값
Table 1. Optimal output pixel values and specific values for the learning layer

Learning layer	pix2pix NP	pix2pix NF	Proposed NP	Proposed NF
1	256×256	64	256×256	32
2	125×125	128	125×125	64
3	60×60	256	14×14	128
4	27×27	512	2×2	128
5	11×11	512	N/A	N/A
6	3×3	512	N/A	N/A
7	1×1	512	N/A	N/A

그림 4는 실험영상 조건 256×256에서 은닉 유닛의 계층 수에 따른 결과를 보여준다. 5개의 계층과 6개의 계층으로 생성된 영상을 보면 계층의 수가 결과 성능에 비례한 관계가 아님을 알 수 있다. 영상 사이즈로부터 계층을 줄이기 위해서는 조건식을 만족해야하며 시스템 매개 변수($NP \times NF$)가 기존 방식과 대략적으로 일치해야한다.




그림 4. 실험에 사용된 입력영상과 결과영상:
(a) 입력영상(왼쪽)과 ground truth(오른쪽), (b) 은닉 유닛 수에 따른 결과영상

Fig. 4. Input and result images of experiments: (a) Input image(left) and ground truth(right), (b) result images for different numbers of hidden units

조건식으로부터 일치한 7계층으로 구성된 이전 방식은 4계층으로 구성 할 수 있다. 이로 인하여 결과를 도출하는데 필요한 학습 데이터의 수가 17283에서 270로 줄어든다. 또한 결과 성능에서도 4개의 계층을 사용한 결과가 기존 7개의 계층을 사용한 결과보다 테이블, 바닥, 옷장 등에서 색상 왜곡 현상이 개선됨이 확인된다.

영상 변환 후 잡음 개선을 위해 경계 강화와 잡음 블러링(Blurring)을 연결하여 적용하였다. 잡음 왜곡을 줄이기 위하여 먼저 라플라시안 필터를 이용하여 영상의 경계를 강조하고 다음 바이래터럴 필터를 사용하여 강한 경계를 유지하면서 잡음을 제거하였다[9][10].

바이래터럴 필터는 화소 사이의 공간에서의 근사성과 명암도의 차이를 이용한 비선형 필터로써 경계를 보존하고 잡음을 줄여주어 부드러운 영상이 만들어지게 되며 식 (4)와 같이 정의된다.

$$BF = \frac{1}{W} \sum_{x_i \in \omega} f(\|I(x_i) - I(x)\|) g(\|x_i - x\|) I(x_i) \quad (4)$$

$$W = \sum_{x_i \in \omega} f(\|I(x_i) - I(x)\|) g(\|x_i - x\|) \quad (5)$$

여기서 BF 는 필터링 된 결과 영상이고, ω 는 필터의 크기를 나타낸다. 함수 f 와 g 는 각각 레벨 영역 가우시안(Gaussian) 함수와 공간영역 가우시안 함수를 의미한다. W 는 BF 를 정규화하기 위해 나누어 주었다.

IV. 실험 및 결과

구현과 결과 비교를 위한 실험에 사용된 데이터 셋은 관련 논문에서 제공하는 밤낮 데이터 셋 17823쌍 중 낮 영상 90장을 선택하여 EV 데이터와 함께 270쌍을 사용 하였다[3]. 그림 5~10는 제안 방법, 기존 방법인 pix2pix와 Cycle GAN을 300 에포크(Epoch)와 데이터 셋으로 훈련한 결과이다. 여기서 그림 5~8은 EV를 낮춘 가상의 밤 영상에 대한 결과이며 그림 9~11은 실제 밤 영상에 대한 결과이다.

그림 5(c)와 5(d)는 기존 Cycle GAN 방법과 pix2pix 방법이며 그림5(e)는 제안된 방법으로 기존 방법에서는 컬러 체크의 색이 왜곡되는 반면 제안 영상은 색이 정답 영상과 유사하게 보존 된다. 지역적 대비(Local contrast) 또한 이전 방식보다 성능이 뛰어남을 보여준다. 그리고 제안한 방법에서는 기존 방법에서 발생한 잡음이 제거되고 영상 경계 성분 또한 강조 되었다.

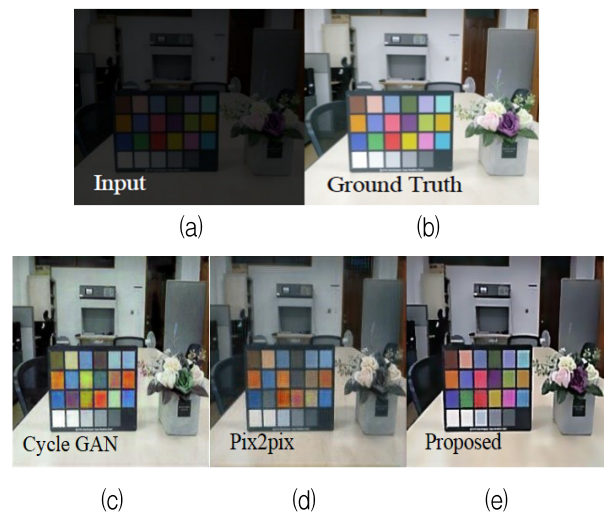


그림 5. 실내 영상 1
Fig. 5. Indoor scene 1

14 어두운 환경 감시를 위한 GAN 기반 영상 변환 기법

그림 6에서는 제안 방법과 비교하여 pix2pix가 테이블이나 옷장에 객체 경계를 넘어서 관련 없는 색을 생성했고 Cycle GAN은 옷장이나 바닥의 색을 왜곡시켰다. 그림 7의 하늘영역에서 강한 잡음이 Cycle GAN과 pix2pix의 영상들에서 관찰되어 진다. 그러나 제안한 방법은 기존 방법보다 색상 왜곡과 잡음이 줄었고 어두운 영역은 더 잘 개선되었다.

그림 8과 9에서는 pix2pix의 밝기의 변화가 제안 방법에 보다 적고 Cycle GAN은 밝기가 개선되었지만 제안 방법에 비해 어둡고 하늘과 잔디의 색상을 왜곡시켰다.

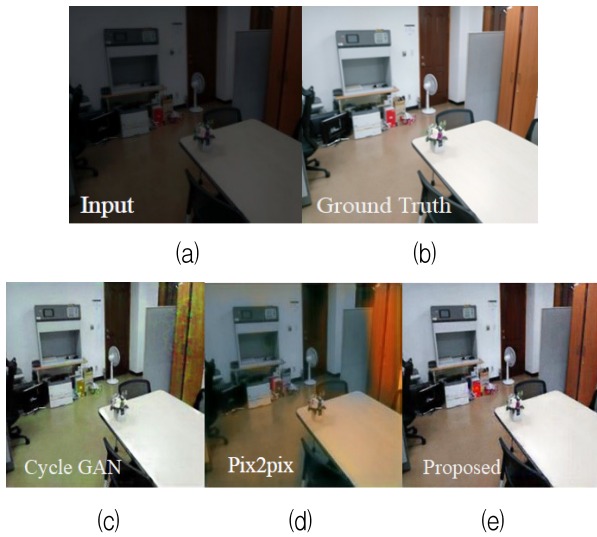


그림 6. 실내 영상 2
Fig. 6. Indoor scene 2

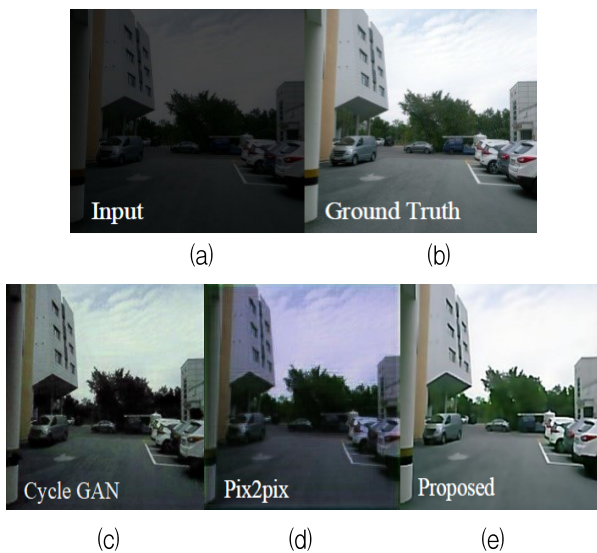


그림 7. 실외 영상 1
Fig. 7. Outdoor scene 1

그림 10에서는 제안 방법이 기존 방법들보다 채도 복원 성능이 더 우수하며 정답 영상과 유사하게 복원되었다. 그림 11에서 pix2pix는 전체 영상의 색상을 왜곡시켰고 Cycle GAN의 영상 밝기는 정답 영상과 제안 방법에 비해 많이 어둡다. 또한 원본 일부 영역에서 원본색상을 유지 하지 못하였다.

실험 결과는 제안된 방법이 기존 방법보다 색상 왜곡이 적고 잡음 또한 개선되었다. 어두운 영역에 대한 밝기 복원 성능도 기존 방법보다 잘 개선되어 정답 영상에 유사하게 복원되어진다.

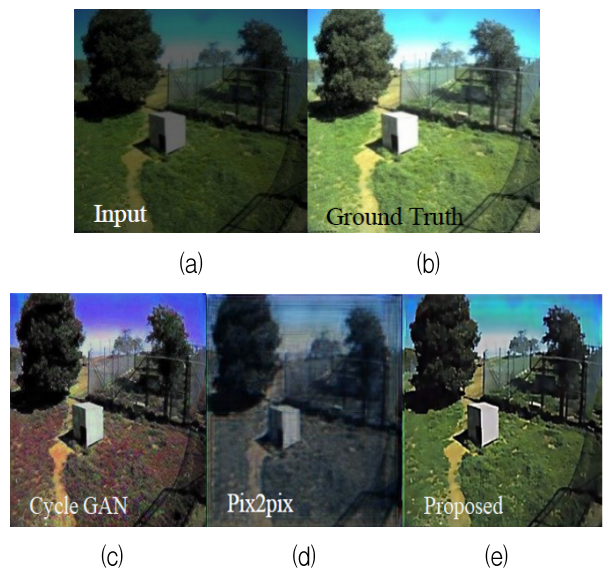


그림 8. 실외 영상 2
Fig. 8. Outdoor scene 2

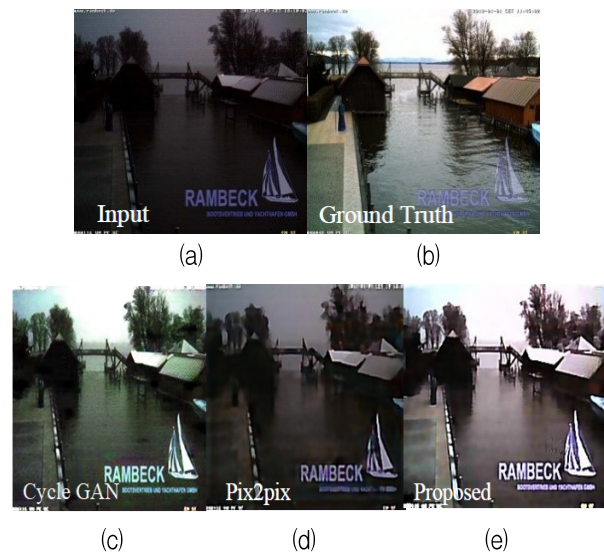


그림 9. 실외 영상 3
Fig. 9. Outdoor scene 3

추가적으로 정량적 평가를 위해서 PSNR(Peak Signal-to-Noise Ratio)과 MOS(Mean Opinion Score)를 사용하였다[11]. PSNR은 영상에서 화질 손실 정보를 평가할 때 사용하고 단위는 데시벨(dB)이며 값이 클수록 성능이 좋음을 의미한다. 생성 영상과 정답영상 간의 PSNR의 수치를 통해 얼마나 유사한지를 알아 볼 수 있지만 GAN은 새로운 픽셀을 생성하기 때문에 이 평가 방법으로는 판단하기 어려울 수 있으므로 결과 성능에 확실히 납득 할 수 있는 방법으로 MOS를 사용하였다[11].

MOS는 정답 영상과 비교하여 1(bad quality) ~ 5(Excellent quality) 사이의 값을 가지며 5에 가까울수록 높은 품질을 나타낸다. 그림 12~13은 그림 5~11의 정량적 평가를 PSNR과 MOS의 결과 그래프로 표시한 것이다. PSNR의 차이는 평균적으로 Cycle GAN 보다 13.62 dB 차이를 보이고, pix2pix 보다 6.22 dB 차이를 보여 더 좋은 성능을 보인다. 또한 MOS의 경우 Cycle GAN은 평균 2.71점, pix2pix는 평균 2.14점을 보이며 제안 방법은 3.71점을 보여 복원 영상과 정답 영상의 사이의 유사도 또한 제안 방법이 더 가깝게 복원됨을 알 수 있다. 이는 그림 12~13에서 확인할 수 있다.

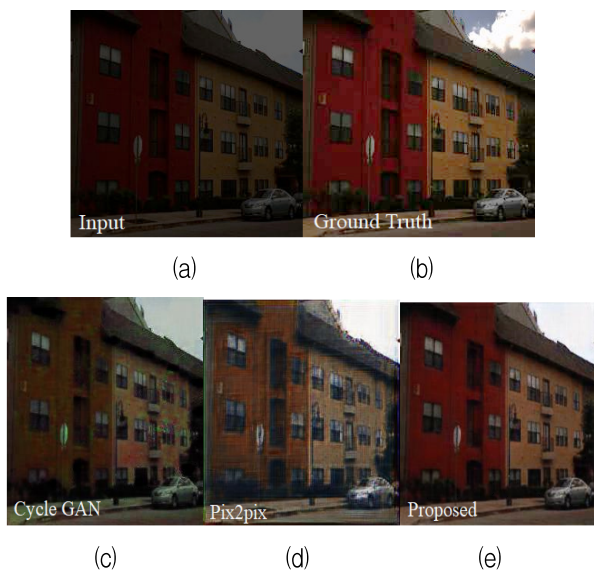


그림 10. 실외 영상 4
Fig. 10. Outdoor scene 4




그림 11. 실외 영상 5
Fig. 11. Outdoor scene 5




그림 12. PSNR 성능 평가
Fig. 12. Evaluation of PSNR performance

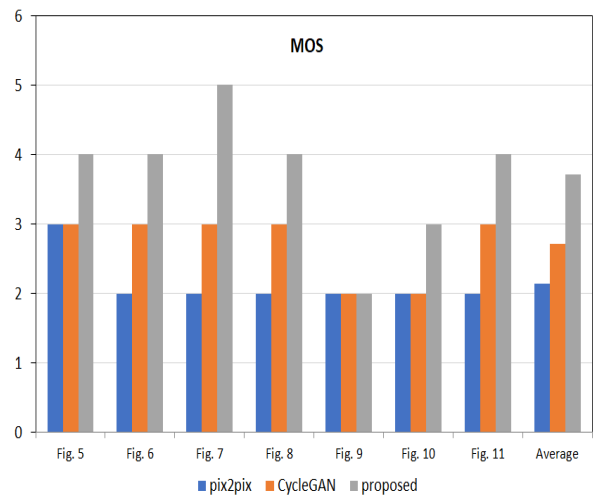


그림 13. MOS 성능평가
Fig. 13. Evaluation of MOS performance

V. 결 론

본 논문에서는 실제 CCTV 등과 같이 보안, 감시 활용을 위해서 생산적 적대 신경망 재구성 하여 밤 영상을 낮 영상으로 바꾸는 방법에 대해서 제안하였다.

Pix2pix의 문제점인 학습 영상과 목표 영상의 공간적 일치성에 대한 제한 상황과 영상 포화에 따른 색 정보 손실 문제를 해결하기 위해 목표 영상의 노출 값을 다르게 하여 학습 영상을 생성하였다. 다음으로 기울기 소실 문제를 해결하기 위해 은닉 유닛을 재구성 하였다.

그 결과 색상 왜곡의 문제를 해결하고 기존 방식 보다 적은 양의 학습으로도 성능이 개선됨을 확인하였다. 그리고 결과 영상에서 발생하는 잡음 및 영상 경계의 왜곡을 개선하기 위해 라플라시안 필터와 바이래터럴 필터를 사용하였다.

실험에서 기존 방법과 제안한 방법의 비교 결과 색상 왜곡과 잡음 문제에 대해 제안한 방법이 기존 방식보다 우수한 성능을 보인다. 그리고 추가적인 PSNR과 MOS 지표를 이용한 각각의 정량적 평가에서 제안한 방법이 Cycle GAN 보다 PSNR 73%, MOS 36% 각각 개선되었고, pix2pix 보다 PSNR 52%, MOS 75% 정도 개선된 결과를 보여준다.

References


- [1] I. Goodfellow, J. Pouget-Abadi, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Ben-gio, "Generative adversarial nets", *Advance Neural Information Processing Systems(NIPS)*, pp. 2672-2680, Mar. 2014.
- [2] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, and W. Shi, "Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network", *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, pp. 105-114, Jul. 2017.
- [3] P. Isola, J. Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-image translation with Conditional Adversarial Networks", *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, pp. 5967-5976, Jul. 2017.
- [4] G. Eilertsen, J. Kronander, G. Denes, P. Mantiuk, and J. Unger, "HDR image reconstruction from a single exposure using deep CNNs", *ACM Transactions on Graphics*, Vol. 36, No. 6, Article No. 178, Nov. 2017.
- [5] Y. LeCun, B. Boser, J. S. Denker, and D. Henderson, "Backpropagation Applied to Handwritten Zip Code Recognition", *Neural Computation*, Vol. 1, No. 4, pp. 541-551, Winter 1989.
- [6] Y. Yu, Z. Gong, P. Zhong, and J. Shan, "Unsupervised Representation Learning with Deep Convolutional Neural Network for Remote Sensing Images", *Springer International Publishing*, Vol. 10667, pp. 97-108, Dec. 2017.
- [7] P. Baldi, "Autoencoders, unsupervised learning, and deep architectures", *Proceedings of ICML Workshop on Unsupervised and Transfer Learning, JMLR Workshop and Conference Proceedings*, Vol. 27, pp. 37-50, Jul. 2011.
- [8] S. W. Jung, D. M. Son, H-J Kwon, and S. H. Lee, "Regional Weighted Generative Adversarial Network for LDR to HDR Image Conversion", *International Conference on Artificial Intelligence in Information and Communication (ICAIC)*, Fukuoka, Japan, pp. 697-700, Feb. 2020.
- [9] F. Durand and J. Dorsey, "Fast bilateral filtering for the display of high-dynamic-range images", *SIGGRAPH '02: Proceedings of the 29th annual conference on Computer graphics and interactive techniques*, San Antonio Texas, pp. 257-266, Jul. 2002.
- [10] S. H. Lee and H. J. Kwon, "HDR Base and Detail Layer Separation Based on the Visual CSF in the Segmented Levels of the Fast Bilateral Filter", *Journal of KIIT*, Vol. 16, No. 7, pp. 57-65,

Jul. 2018.

[11] R. C. Streijl, "Mean opinion score (MOS) revisited: methods and applications", limitations and alternatives. Multimedia Systems, Vol. 22, pp. 213-227, Dec. 2016.

저자소개

정 성 운 (Sung-Woon Jung)



2019년 2월 : 안동대학교
전자공학과(공학사)
2019년 3월 ~ 현재 : 경북대학교
전자공학부(석사과정)
관심분야 : 영상처리, 인공지능

권 혁 주 (Hyuk-Ju Kwon)



2010년 2월 : 경북대학교 전자전기
컴퓨터학부(공학사)
2012년 2월 : 경북대학교
전자전기컴퓨터학부(공학석사)
2017년 9월 : 경북대학교
전자공학부(박사후 연구원)
2019년 8월 : 아진산업 선행연구팀

연구원

2019년 8월 ~ 현재 : 경북대학교 전자공학부 계약교수
관심분야 : Color Image Processing, Color Management
HDR 영상처리, 적외선 영상처리, 인공지능

김 영 춘 (Young-Choon Kim)



1991년 2월 : 경북대학교
전자공학과(공학사)
1993년 2월 : 경북대학교
전자공학과(공학석사)
1997년 2월 : 경북대학교
전자공학과(공학박사)
1998년 2월 ~ 현재 : U1대학교

정보통신보안학과 교수

관심분야 : 영상처리, 적외선 영상처리, 컴퓨터비전,
IRCM

안 상 호 (Sang-Ho Ahn)



1986년 2월 : 경북대학교
전자공학과(공학사)
1988년 2월 : 경북대학교
전자공학과(공학석사)
1992년 8월 : 경북대학교
전자공학과(공학박사)
1993년 ~ 현재 : 인제대학교

전자IT기계자동차공학부 교수

관심분야 : 영상공학, 로봇비전, 적외선 영상처리, IRCM

이 성 학 (Sung-Hak Lee)



1997년 2월 : 경북대학교
전자공학과(공학사)
1999년 2월 : 경북대학교
전자공학과(공학석사)
1999년 2월 ~ 2004년 6월 : LG
전자 영상제품연구소 선임연구원
2008년 2월 : 경북대학교

전자공학과(공학박사)

2009년 8월 ~ 2017년 7월 : 경북대학교 IT대학

전자공학부 연구초빙교수

2018년 3월 ~ 현재 : 경북대학교 IT대학 전자공학부 교수

관심분야 : Color Image Processing, Color Appearance
Model, Color Management, HDR 영상처리, 영상융합,
딥러닝영상처리