

특집논문 (Special Paper)

방송공학회논문지 제23권 제6호, 2018년 11월 (JBE Vol. 23, No. 6, November 2018)

<https://doi.org/10.5909/JBE.2018.23.6.760>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

# 운전자 안정성 향상을 위한 Generative Adversarial Network 기반의 야간 도로 영상 변환 시스템

안 남 현<sup>a)</sup>, 강 석 주<sup>a)†</sup>

## Night-to-Day Road Image Translation with Generative Adversarial Network for Driver Safety Enhancement

Namhyun Ahn<sup>a)</sup> and Suk-Ju Kang<sup>a)†</sup>

### 요 약

첨단 운전자 지원 시스템(ADAS)은 차량 기술 분야에서 활발한 연구가 이루어지고 있는 기술이다. ADAS 기술은 직접적으로 차량을 제어하는 기술과 간접적으로 운전자에게 편의를 제공하는 기술로 나뉜다. 본 논문에서는 야간 도로 영상을 보정하여 운전자에게 시각적 편의를 제공하는 시스템을 제안한다. 제안하는 시스템은 전방 블랙박스 카메라로부터 촬영된 도로 영상을 입력받는다. 입력된 영상은 가로 축을 따라 세 부분으로 분할된 뒤 일괄적으로 이미지 변환 모듈을 통해 각각 낮 영상으로 변환된다. 변환된 영상은 다시 결합된 뒤 운전자에게 제공되어 시각적 편의를 제공한다. 본 논문의 실험 결과를 통해 제안한 시스템이 기존의 밝기 변환 알고리즘과 비교하여 우수한 성능을 보임을 입증한다.

### Abstract

Advanced driver assistance system(ADAS) is a major technique in the intelligent vehicle field. The techniques for ADAS can be separated in two classes, i.e., methods that directly control the movement of vehicle and that indirectly provide convenience to driver. In this paper, we propose a novel system that gives a visual assistance to driver by translating a night road image to a day road image. We use the black box images capturing the front road view of vehicle as inputs. The black box images are cropped into three parts and simultaneously translated into day images by the proposed image translation module. Then, the translated images are recombined to original size. The experimental result shows that the proposed method generates realistic images and outperforms the conventional algorithms.

Keyword : Image translation, Image enhancement, Deep learning, Cycle consistency, Generative adversarial network

a) 서강대학교 전자공학과(Dept. of Electronic Engineering, Sogang University)

† Corresponding Author : 강석주(Suk-Ju Kang)

E-mail: [sjkang@sogang.ac.kr](mailto:sjkang@sogang.ac.kr)

Tel: +82-2-705-8466

ORCID: <https://orcid.org/0000-0002-4809-956X>

※ 이 논문의 연구결과 중 일부는 “한국방송·미디어공학회 2018년 하계학술대회”에서 발표한 바 있음.

※ This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ITRC(Information Technology Research Center) support program(IITP-2018-0-01421) supervised by the IITP(Institute for Information & communications Technology Promotion, and by the Korea Institute of Energy Technology Evaluation and Planning (KETEP) and the Ministry of Trade, Industry & Energy (MOTIE) of the Republic of Korea (No. 20161210200560)

· Manuscript received September 4, 2018; Revised October 10, 2018; Accepted October 31, 2018.

Copyright © 2016 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

## I. 서론

최근 하드웨어 연산 능력의 향상과 차량 부품의 점차적인 전장화에 따라, 자율 주행 및 첨단 운전자 지원 시스템(ADAS)에 대한 연구가 활발해지고 있다. ADAS 기술은 크게 두 종류로 구분될 수 있다. 첫 번째로 차량 외부 상황을 인식하고 직접적으로 차량을 제어하는 방식의 기술이 있다. 차선을 인식하고 차량이 차선 밖으로 이탈하지 않도록 제어하는 차선 이탈 제어 시스템과 전방 차량과의 거리를 인식하고 충돌하지 않도록 차량을 제어하는 전방 추돌 방지 시스템 등이 있다<sup>[1]</sup>. 외부 상황에 대한 인식 기술은 최근 상당한 기술적 발전을 이루었지만, 날씨나 측광에 따라 인식 성능이 저하되는 문제점이 여전히 존재한다<sup>[2]</sup>. 잘못된 인식 결과는 안전사고로 이어질 수 있기 때문에 해당 기술들은 상용화에 어려움이 있다. 이와 달리 직접적으로 차량을 제어하지 않고 간접적으로 운전자에게 편의를 제공하는 ADAS 기술이 있다. 운전자의 졸음 상태를 인식하고 경고하는 졸음 인식 시스템과 맞은편 차선의 차량을 인식하고 헤드라이트의 방향을 조절하는 적응적 헤드라이트 조절 시스템 등이 있다<sup>[1]</sup>. 관련 기술들은 직접적으로 차량 제어에 관여하지 않으므로 오작동으로 인한 사고의 위험성이 적으며, 상용화에 직결될 수 있는 기술이다.

교통안전 사고의 상당 부분은 야간에 발생한다. 야간 상황에서 운전자는 시각적 제한을 받기 때문에 인지적 오류로 인한 안전사고가 발생할 가능성이 높다<sup>[3]</sup>. 헤드라이트의 밝기와 각도 조절을 통해 운전자의 시야를 확보할 수 있지만, 이는 맞은편 차량의 시야를 제한하는 문제를 야기할 수

있다<sup>[4]</sup>. 본 논문에서는 헤드라이트의 제어 없이 야간 상황에서 운전자의 시야를 확보하는 기술을 제안한다. 제안하는 시스템은 블랙박스를 통해 전방 도로 영상을 촬영하고 이를 주간 영상으로 변환한다. 변환된 영상은 운전자에게 제공되어 시각적 제한을 개선시켜준다.

## II. 제안하는 시스템

### 1. 전체 시스템 개요

제안하는 시스템의 전체 구성은 그림 1과 같다. 전방 도로 영상이 입력으로 들어오면 해당 영상은 먼저 가로 축을 따라 균일하게 세 부분으로 나뉜다. 나뉜 영상은 각각 이미지 변환 모듈의 입력 사이즈에 맞게 크기가 조정된다. 조정된 영상은 일괄적으로 묶여 이미지 변환 모듈을 통과하며 각각 낮 영상으로 변환된다. 변환된 세 장의 영상은 다시 원본 영상 사이즈로 크기가 조정되고, 최종적으로 원본 전체 영상의 순서에 맞게 다시 결합된다.

제안하는 시스템은 입력 영상을 patch 단위로 나누어 변환한다. 이와 같은 과정은 학습 기반의 알고리즘을 사용하는 이미지 변환 모듈의 학습 과정을 용이하게 한다. 제안하는 시스템의 이미지 변환 모듈은 Convolutional neural network(CNN) 기반의 이미지 변환 알고리즘을 사용한다. CNN 기반의 알고리즘은 일반적으로 가로 및 세로의 해상도가 512 이하인 영상을 입력으로 사용한다. 학습 과정에서 많은 메모리 사용량을 요구하는 알고리즘의 특성상 높은

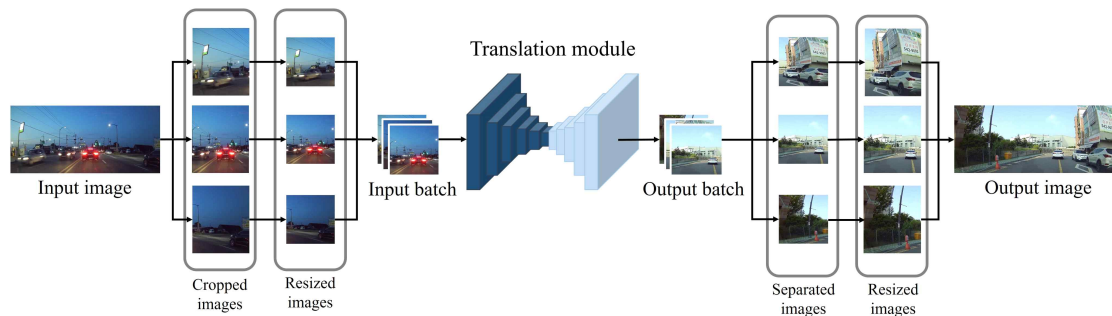


그림 1. 운전자 안전성 향상을 위한 Generative Adversarial Network 기반의 야간 도로 영상 변환 시스템 개념도  
 Fig. 1. Concept of the night-to-day road image translation with generative adversarial network(GAN) for driver safety enhancement

해상도를 가지는 영상의 사용이 불가하다. 따라서 높은 해상도의 입력 영상을 처리해야하는 문제의 경우 일반적으로 patch 단위로 영상을 처리한다<sup>[4]</sup>. 본 논문에서 제안하는 시스템은 Full-HD 해상도의 블랙박스 영상을 입력으로 사용한다. 따라서 입력 영상을 이미지 변환 모듈에 통과시키기 전에 영상을 patch 단위로 나누는 전처리 과정을 수행한다. Patch 단위로 나뉜 영상은 동일한 사이즈로 크기가 조정된 후 이미지 변환 모듈을 통과한다. 변환된 입력 영상은 원래 순서에 맞게 다시 결합된 후 출력된다.

## 2. 이미지 변환(Image translation) 알고리즘

이미지 변환(Image translation)이란 특정 도메인 내의 영상을 다른 도메인의 영상으로 변환하는 과정을 의미한다. 가령, 흑백 영상을 컬러 영상으로 바꾸는 변환이 이에 해당된다. 이미지 변환의 개념은 non-parametric texture model<sup>[5]</sup>을 사용한 Hertmann et al.의 논문 Image Analogies<sup>[6]</sup>에서 처음 등장하였다. 최근에는 CNN을 기반으로 한 parametric method에 대한 연구가 활발히 이루어지고 있다. 제안하는 시스템은 CNN 기반의 이미지 변환 알고리즘인 CycleGAN<sup>[7]</sup>을 이용하여 야간 도로 영상을 주간 도로 영상으로 바꾸는 이미지 변환을 수행한다.

CycleGAN은 쌍으로 존재하지 않는 영상 데이터(Unpai-

red image data)를 사용하는 학습 기반의 이미지 변환 알고리즘이다. 야간 도로 영상의 경우 대응되는 주간 도로 영상의 수집이 불가하다. 동일한 도로에서 촬영이 이루어지더라도 주변의 차량이나 보행자의 유무가 동일할 수 없다. 따라서 제안하는 시스템은 CycleGAN 알고리즘을 사용하여 해당 문제를 극복하였다.

그림 2는 CycleGAN의 전체 모델 구조를 보여준다. CycleGAN은 Generator AB, Generator BA, Discriminator A, Discriminator B, 4개의 컨볼루션 네트워크(CNN)로 구성된다. Generator AB는 도메인 A의 영상을 도메인 B의 영상으로 변환하는 과정을 수행하고, Generator BA는 도메인 B의 영상을 도메인 A의 영상으로 변환하는 과정을 수행한다. Discriminator A는 Generator BA에 의해 변환된 영상(Image BA)과 도메인 A로부터 임의 선택된 실제 영상(Image A)을 구분하는 역할을 수행한다. 마지막으로 Discriminator B는 Generator AB에 의해 변환된 영상(Image AB)과 도메인 B로부터 임의 선택된 실제 영상(Image B)을 구분하는 역할을 수행한다. 해당 모델 구조는 특정 도메인 A의 영상을 다른 도메인 B의 영상으로 대응시켜주는 함수가 존재하면 그 역대응 함수 역시 존재한다는 점에 착안하여 고안되었다.

각 4개의 네트워크는 3개의 손실 함수를 통해 파라미터를 학습한다. Discriminator A는 도메인 A로부터 선택된 실

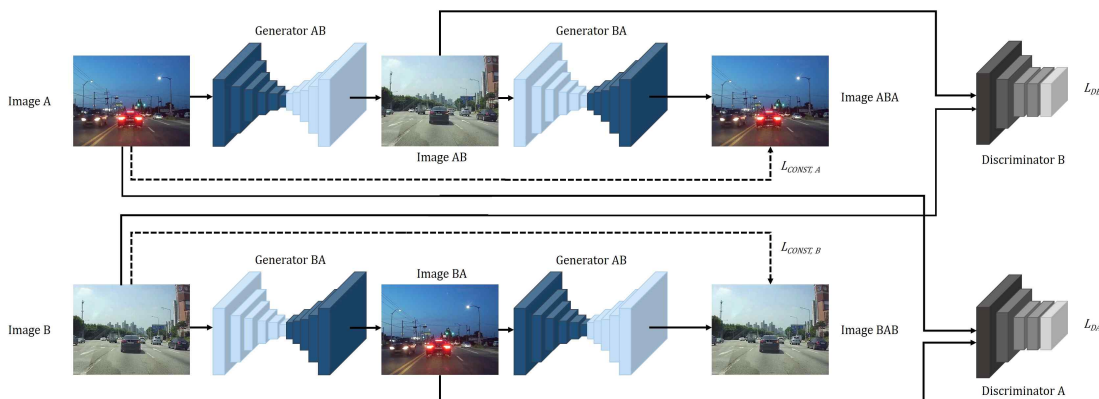


그림 2. 제안하는 이미지 변환 알고리즘(CycleGAN)의 학습 모델 구조. 학습 모델은 Generator AB, Generator BA, Discriminator A, Discriminator B 총 네 개의 네트워크로 구성되며,  $L_{DA}$ ,  $L_{DB}$ ,  $L_{CONST,A}$ ( $L_{CONST,A}$ ,  $L_{CONST,B}$ ) 총 세 개의 손실함수를 통해 학습된다.

Fig. 2. The overall structure of training system for the proposed image translation module(CycleGAN). It consists of 4 network; Generator AB, Generator BA, Discriminator A, Discriminator B, and trained by 3 loss functions;  $L_{DA}$ ,  $L_{DB}$ ,  $L_{CONST,A}$ ( $L_{CONST,A}$ ,  $L_{CONST,B}$ )

제 영상이 입력으로 들어왔을 때 1을 출력하고, Generator BA로부터 변환된 영상이 입력으로 들어왔을 때 0을 출력하도록 학습한다. Discriminator B도 이와 동일하게 도메인 B로부터 선택된 실제 영상이 입력으로 들어왔을 때 1을 출력하고, Generator AB로부터 변환된 영상이 입력으로 들어왔을 때 0을 출력하도록 학습한다. 이를 위한 손실 함수는 식 (1)과 같이 adversarial loss<sup>[8]</sup>로 정의된다.

해당 식에서  $G_{AB}$ ,  $G_{BA}$ ,  $D_A$ ,  $D_B$ 는 각각 Generator AB, Generator BA, Discriminator A, Discriminator B를 의미한다.  $x_A \sim p_{data}(x_A)$ ,  $x_B \sim p_{data}(x_B)$ 는 각각 도메인 A와 B에 속하는 영상들의 분포를 나타내며,  $x_A$ ,  $x_B$ 는 각 분포로부터 임의 선택된 샘플 영상을 의미한다. 학습 과정에서 Discriminator A는  $L_{DA}$ 를 감소시키는 방향으로 파라미터를 갱신하고, Discriminator B는  $L_{DB}$ 를 감소시키는 방향으로 파라미터를 갱신한다. 손실 함수  $L_{DA}$ 와  $L_{DB}$ 가 작아질수록 Discriminator들은 실제 영상과 변환된 영상을 잘 구분하게 된다.

Generator AB와 Generator BA는 Discriminator와는 반대로  $L_{DB}$ 와  $L_{DA}$ 를 증가시키는 방향으로 파라미터를 갱신한다. 학습 과정에서 Discriminator가 구분할 수 없도록

더 실제와 가까운 영상을 생성하도록 학습이 이루어진다.  $L_{DA}$ 와  $L_{DB}$ 가 증가할수록 Generator는 Discriminator가 구분하기 어려운 영상을 생성하게 된다. 또한, Generator AB와 Generator BA는 추가적으로 cycle consistency loss<sup>[7]</sup>를 학습에 사용한다. Cycle consistency loss는 식 (2)와 같이 정의된다.

해당 손실 함수는 Generator AB을 통해 변환된 영상이 Generator BA를 통해 변환되었을 때 원본 영상  $x_A$ 과 동일하도록 두 Generator를 학습시킨다. 또한, 동일하게 Generator BA를 통해 변환된 영상이 Generator AB를 통해 변환되었을 때 원본 영상  $x_B$ 로 복원되도록 Generator를 학습시킨다. 결과적으로, Generator AB는  $L_{DB}$ 와  $L_{CONST}(G_{AB}, G_{BA})$ 를 감소시키는 방향으로 학습이 진행되며, Generator BA는  $L_{DA}$ 와  $L_{CONST}(G_{AB}, G_{BA})$ 를 감소시키는 방향으로 학습이 진행된다.

### 3. 세부 학습 과정

본 논문에서는 야간 도로 영상을 도메인 A, 주간 도로 영상을 도메인 B로 설정하고 CycleGAN 알고리즘을 학습

$$\begin{aligned} L_{DA}(G_{BA}, D_A) &= E_{x_A \sim p_{data}(x_A)} [\log D_A(x_A)] + E_{x_B \sim p_{data}(x_B)} [\log(1 - D_A(G_{BA}(x_B)))] \\ L_{DB}(G_{AB}, D_B) &= E_{x_B \sim p_{data}(x_B)} [\log D_B(x_B)] + E_{x_A \sim p_{data}(x_A)} [\log(1 - D_B(G_{AB}(x_A)))] \end{aligned} \quad (1)$$

$$\begin{aligned} L_{CONST}(G_{AB}, G_{BA}) &= E_{x_A \sim p_{data}(x_A)} [\|G_{BA}(G_{AB}(x_A)) - x_A\|_1] \\ &\quad + E_{x_B \sim p_{data}(x_B)} [\|G_{AB}(G_{BA}(x_B)) - x_B\|_1] \end{aligned} \quad (2)$$



그림 3. 영상 데이터 샘플. 왼쪽 두 열은 야간 도로 영상 (도메인 A)의 샘플이며 오른쪽 두 열은 주간 도로 영상 (도메인 B)의 샘플이다.  
Fig. 3. Example images in collected data. Left two columns: night road images (domain A), right two columns: day road images (domain B)



그림 4. 이미지 변환 알고리즘 별 정성적 결과 비교. 각 행은 입력 영상에 따른 알고리즘 별 출력 영상을 나타낸다. 왼쪽부터 순서대로 입력, 히스토그램 평활화, 감마 보정, 제안하는 시스템.

Fig. 4. Qualitative results of different methods for night-to-day road image translation. Each row shows the output images of compared algorithms for each input. From left to right: input, histogram equalization, gamma correction, proposed system.

시켰다. 학습된 알고리즘에서 Generator AB만을 추출하여 그림 1과 같은 시스템을 구현하였다. 데이터는 야간 도로 영상과 주간 도로 영상 각 2,000장 가량을 직접 수집하였으며, 이 중 각 1800장은 학습 데이터로 사용하고 각 200장은 평가 데이터로 사용하였다. 그림 3은 수집한 영상의 샘플을 보여준다. 학습 과정에서 데이터양을 늘리기 위해 입력 영상을 random crop과 horizontal flip을 적용하였다. 사용한 최적화 기법은 Adam optimization이며, 학습률은 0.0002로 고정시켰다. 학습은 batch size를 1로 설정하고 총 30 epoch 만큼 진행하였다. 실제 학습 시 손실 함수는 본문 II-2에서 언급한 cross entropy기반의 adversarial loss 대신 least square 기반의 adversarial loss<sup>[9]</sup>를 사용하였다.

### III. 실험 결과

#### 1. 정성적 성능 평가

본 논문에서는 기존의 밝기 변환 알고리즘인 히스토그램 평활화<sup>[10]</sup>와 감마 보정<sup>[11]</sup>을 제안하는 시스템과 비교한다. 그림 4는 각 이미지 변환 알고리즘의 정성적 결과를 보여준다. 위 두 행의 영상은 도로 주행 상황에서 촬영된 영상을 입력으로 사용한 결과이며, 아래 세 행의 영상은 주택가 주변 주행 상황에서 촬영된 영상을 사용한 결과이다. 히스토그램 평활화를 통해 생성된 영상의 경우 자동차 후미등 및 신호등이 번져 보이는 문제가 발생한다. 또한, 감마 보정을

표 1. 알고리즘 별 NIQMC 비교 결과. NIQMC는 기준 영상 없이 영상의 밝기 왜곡 정도를 평가하는 척도이다. 표의 각 행은 그림 4의 각 행 영상을 대상으로 NIQMC를 측정된 결과이다. 오른쪽부터 순서대로 입력, 히스토그램 평활화, 감마 보정, 제안하는 시스템

Table 1 NIQMC values of different methods for night-to-day road image translation. NIQMC is no-reference quality metric of contrast-distorted images. Each row shows NIQMC values of images for each rows in Fig 4. From right to left: input, histogram equalization, gamma correction, proposed system.

Image	Input	Gamma.	Histogram.	Proposed.
Image1	5.3644	5.3891	5.6637	5.8893
Image2	5.2589	5.1080	5.4777	5.8427
Image3	4.2399	4.9186	5.6282	5.8962
Image4	5.1833	4.8259	5.4061	5.8735
Image5	4.0357	4.4645	5.5077	5.9163

통해 생성된 영상의 경우는 영상 전체가 안개 낀 듯 흐려지는 문제가 발생한다. 이와 달리 제안하는 시스템의 경우 기존 알고리즘과 같은 열화 현상 없이 밝기가 보정된 영상을 생성함을 확인 할 수 있다. 또한, 기존 알고리즘의 경우 단순히 영상 전체의 밝기를 일정 수준 증가시키는데 반해 제

안하는 알고리즘의 경우 단순히 밝기를 증가시키는 것을 넘어 원본 영상을 완전한 주간 영상으로 변환시키는 것을 확인할 수 있다. 따라서 기존 방법들에 비해 시각적으로 더 개선된 영상을 생성함을 확인할 수 있다.

## 2. 정량적 성능 평가

영상의 품질을 평가하는 척도로 흔히 Peak Signal-to-Noise Ratio(PSNR)와 Structural Similarity(SSIM)<sup>[12]</sup>를 사용한다. 하지만, 해당 척도들은 기준이 되는 이상적인 영상 (Ground truth)이 존재할 때 적용이 가능하다. 본 논문에서는 입력 야간 영상에 대응되는 이상적인 주간 영상을 얻을 수 없기 때문에 해당 방법들을 적용할 수 없다. 따라서 이상적인 영상 없이 영상의 밝기 왜곡 정도를 평가하는 No-reference Image Quality Metric for Contrast distortion (NIQMC)<sup>[15]</sup>를 평가 척도로 사용한다. 해당 척도는 값이 높을수록 왜곡 정도가 적음을 나타낸다.

표 1은 제안한 방법을 사용해 각 알고리즘을 평가한 결과

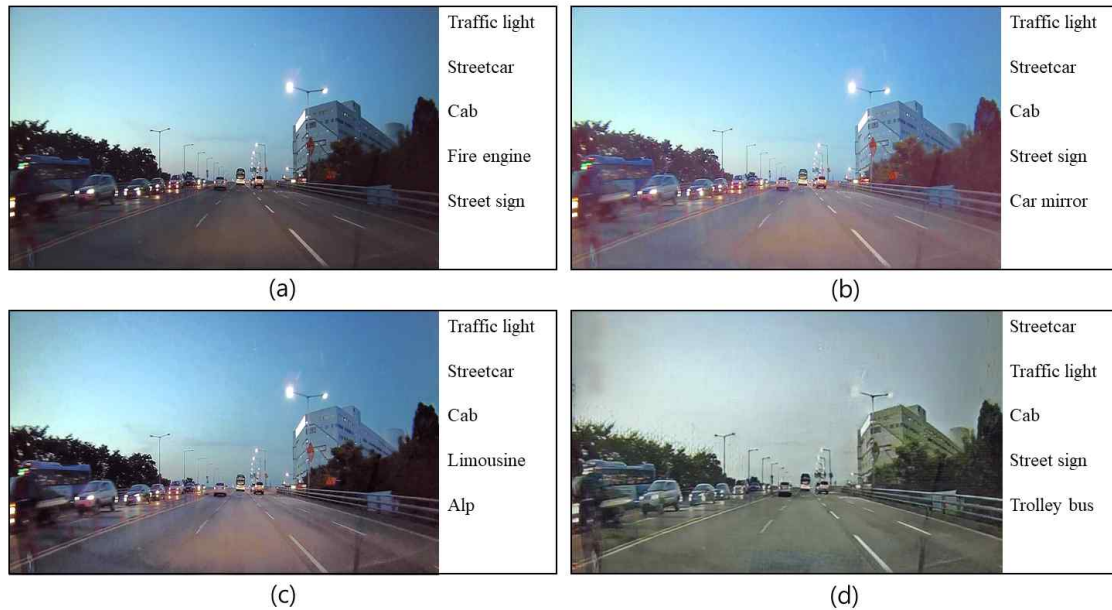


그림 5. 동일 영상 기반 알고리즘 별 오 분류 결과 비교. (b) ~ (d)의 영상은 입력 영상 (a)에 대해 각 이미지 변환 알고리즘을 적용한 결과 영상을 나타낸다. 각 그림의 오른쪽 5개의 class는 해당 영상을 Inception 네트워크에 통과시켰을 때 나오는 Top-5 class를 의미한다. (a) 입력 영상, (b) 감마 보정, (c) 히스토그램 평활화, (d) 제안하는 시스템.

Fig. 5. Misclassification results of each algorithm for same image. (b) ~ (d) show the translated images of (a) by each image translation method. The 5 classes at the right side of the pictures represents Top-5 classes. (a) Input, (b) Gamma correction, (c) Histogram equalization, (d) Proposed system.

를 보여준다. 표의 각 행은 그림 4의 각 행 영상들을 대상으로 NIQMC를 측정된 결과를 나타낸다. 실험 결과 제안한 방법을 통해 영상을 보정하였을 때, 모든 영상의 NIQMC 값이 원본 영상과 비교하여 개선됨을 확인할 수 있다. 또한, 다른 밝기 보정 알고리즘과 비교하였을 때 제안하는 방법에 의해 생성된 영상이 가장 높은 NIQMC 수치를 갖는 것을 확인할 수 있다. 특히, 감마 보정을 통해 밝기를 보정하는 경우 결과 영상의 NIQMC 값이 원본 영상보다 작아지는 현상이 발생함을 확인할 수 있다.

또한, 제안하는 방법에 의해 생성된 영상은 사람의 인지적 측면에서 개선되었을 뿐만 아니라 컴퓨터비전 관점에서도 개선된 결과를 보여준다. 이를 입증하기 위해 본 논문에서는 각 알고리즘을 통해 생성된 영상을 컴퓨터비전 분야에서 높은 성능을 보이는 Inception network<sup>[16]</sup>에 적용하여 그 결과를 분석한다. Inception network는 image classification에서 높은 성능을 보이는 딥러닝 기반 알고리즘이다. 이미지 생성 알고리즘 평가에 자주 사용되는 Inception-score<sup>[13]</sup> 역시 Inception network를 기반으로 한 평가 방법이다. 본 논문에서는 각 영상을 Inception network에 통과시켰을 때 나오는 Top-5 class(전체 class 중에서 가장 높은 확률 값을 갖는 5개의 class)를 분석한다. 그림 5는 샘플 입력 영상 및 각 알고리즘을 통해 생성된 영상과 이를 Inception network에 통과시켜 나온 Top-5 class를 나타낸다. 결과를 보면, 원본 영상의 경우 Top-5 class에 입력 영상과 무관한 fire engine이라는 class가 포함되는 것을 확인할 수 있다. 또한, 감마 보정을 통해 생성된 영상의 경우 car mirror라는 오 분류 결과가 포함되는 것을 확인할 수 있으며, 히스토그램 평활화를 통해 생성되는 영상의 경우 alp, limousine과 같은 오 분류되는 결과가 포함되는 것을 확인할 수 있다. 반면, 제안하는 방법에 의해 생성된 영상의 경우 network에 통과시켰을 때 모두 영상에 존재하는 대상에 대한 class로 분류되는 것을 확인할 수 있다. 이를 통해 제안하는 방법에 의해 생성되는 영상이 사람의 인지적 측면에서 뿐만 아니라 컴퓨터비전 관점에서도 개선된 영상임을 확인할 수 있다.

## IV. 결 론

본 논문에서는 이미지 변환 알고리즘인 CycleGAN을 이용한 야간 도로 영상 보정 시스템을 제안하였다. 실험 결과, 기존 알고리즘을 통해 생성된 영상의 경우 일부 열화 현상이 발생하는데 반해 제안하는 시스템을 통해 생성된 영상은 이러한 열화 현상 없이 보정된 영상을 생성함을 입증하였다. 또한, Inception 네트워크 기반의 평가 척도를 사용하여 제안한 시스템을 통해 생성된 영상이 사람의 인지적 측면에서 개선되었을 뿐만 아니라 컴퓨터비전 관점에서도 개선된 영상임을 입증하였다. 따라서 본 논문에서 제안하는 방법을 통해 운전자에게 시각적 편의를 제공하는 운전자 지원 시스템을 구축할 수 있을 것으로 사료된다.

## 참 고 문 헌 (References)

- [1] A. Paul, R. Chauhan, R. Srivastava, and M. Baruah, "Advanced Driver Assistance Systems", SAE Technical Paper 2016-28-0223, 2016, doi:10.4271/2016-28-0223.
- [2] Z. Sun, G. Bebis and R. Miller, "On-road vehicle detection using optical sensors: a review," Proceedings. The 7th International IEEE Conference on Intelligent Transportation Systems (IEEE Cat. No.04TH8749), Washington, WA, USA, pp. 585-590, 2004, doi: 10.1109/ITSC.2004.1398966.
- [3] S. Plainis and IJ. Murray, "Reaction times as an index of visual conspicuity when driving at night", Ophthalmic Physiol Opt., Vol.22, No.5, pp.409-415, Sep, 2002.
- [4] T. Hacibekir, S. Karaman, E. Kural, E.S. Ozturk, M. Demirci and B. Aksun Guvenc, "Adaptive Headlight System Design Using Hardware-In-The-Loop Simulation", 2006 IEEE Conference on Computer Aided Control System Design, 2006 IEEE International Conference on Control Applications, 2006 IEEE International Symposium on Intelligent Control, Munich, Germany, pp.2165-3011, October, 2006, doi:10.1109/CACSD-CCA-ISIC.2006. 4776767.
- [5] A. A. Efros and T. K. Leung. "Texture synthesis by non-parametric sampling", In ICCV, 1999.
- [6] A. Hertzmann, C. E. Jacobs, N. Oliver, B. Curless, and D. H. Salesin. "Image analogies". In SIGGRAPH, pp.327 - 340. ACM, 2001.
- [7] J. Zhu, T. Park, P. Isola, and A.A. Efros, "Unpaired image-to-image translation using cycle-consistent adversarial networks", In ICCV, 2017.
- [8] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. "Generative adversarial nets". In NIPS, 2014.
- [9] X. Mao, Q. Li, H. Xie, R. Y. Lau, Z. Wang, and S. P. Smolley. "Least squares generative adversarial networks", In CVPR, 2017.

- [10] S. -D. Chen, and A. R. Ramli, "Contrast enhancement using recursive mean-separate histogram equalization for scalable brightness preservation," IEEE Transactions on Consumer Electronics, Vol. 49, No. 4, pp.1301-1309, 2003.
- [11] W. Kubinger, M. Vincze and M. Ayromlou, "The role of gamma correction in colour image processing," 9th European Signal Processing Conference (EUSIPCO 1998), Rhodes, pp. 1-4, 1998.
- [12] A. Hore and D. Ziou, "Image Quality Metrics: PSNR vs. SSIM," 2010 20th International Conference on Pattern Recognition, Istanbul, pp. 2366-2369, 2010, doi: 10.1109/ICPR.2010.579.
- [13] T. Salimans, I. Goodfellow, W. Zaremba, V. Cheung, A. Radford, and X. Chen, "Improved techniques for training gans," In Advances in Neural Information Processing Systems, pp. 2234 - 2242, 2016.
- [14] Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., Fu, Y.: Image super-resolution using very deep residual channel attention networks. In ECCV. 2018.
- [15] Ke Gu, Jun Zhou, Jun-Fei Qiao, Guangtao Zhai, Weisi Lin, Alan Conrad Bovik, "No-reference quality assessment of screen content pictures," IEEE Transactions on Image Processing (T-IP), vol. 26, no. 8, pp. 4005-4018, Aug. 2017.
- [16] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna. Rethinking the inception architecture for computer vision. In CVPR, 2016.

---

저 자 소 개



안 남 현

- 2018년 : 서강대학교 전자공학과 졸업(학사)
- 2018년 : 서강대학교 전자공학과 석사 재학
- ORCID : <https://orcid.org/0000-0002-9240-3039>
- 주관심분야 : 컴퓨터비전, 영상처리, 딥러닝



강 석 주

- 2006년 : 서강대학교 전자공학과 졸업
- 2011년 : 포항공과대학교 전자전기공학과 졸업 (공학박사)
- 2011년 ~ 2012년 : LG Display 선임 연구원
- 2012년 ~ 2015년 : 동아대학교 전기공학과 조교수
- 2015년 ~ 현재 : 서강대학교 전자공학 부교수
- ORCID : <https://orcid.org/0000-0002-4809-956X>
- 주관심분야 : 멀티미디어 영상신호처리, 컴퓨터 비전, 딥러닝 시스템 설계