

# CNN 기반 저조도 이미지 개선 및 색상 보정 알고리즘

이인재, 김효영, 고성제\*  
고려대학교 전기전자공학과

{ijlee, hykim}@dali.korea.kr, \*sjko@korea.ac.kr

## CNN Based Low-light Image Enhancement and Color Correction Algorithm

In-Jae Lee, Hyo-Young Kim, Sung-Jea Ko\*  
School of Electrical Engineering Korea University

### 요 약

저조도 영상의 de-noising 분야는 기존 전통 방식은 물론 최근 발전한 종단간 딥러닝 방식을 적용하여 많은 성과를 달성하였다. 하지만 기존 방식은 색상 왜곡과 같은 문제를 발생시킨다. 이 논문에서는 이러한 문제를 극복하기 위해 색상 보정의 효과를 얻을 수 있는 손실 함수를 제안하였다. 실험 결과는 제안된 손실 함수가 저조도 영상의 품질을 효과적으로 개선할 수 있음을 보여준다.

### I. 서 론

저조도 영상 개선 분야는, 더욱 선명한 이미지를 얻고자 하는 사람들의 요구에 따라 여전히 개발 되어야 할 부분이 많은 도전적인 분야로 연구되고 있다[1]. BM3D[2]와 같은 전통 방식의 저조도 개선은 물론, 최근 급속히 발전한 딥러닝 기술을 적용한 저조도 개선 연구 역시 시도되며 여러 성과를 가져왔다[3]. Chen[4]의 경우, 극저조도 (Extreme low-light) 영상과 Ground-truth (이하 GT) 영상을 대상으로 한 대량의 데이터셋을 제안하고 종단간 딥러닝 (end-to-end deep learning) 저조도 개선 알고리즘을 제안하였다. 하지만 매우 적은 광자수 (low photon counts)로 이뤄진 극저조도 영상의 열악한 환경으로 인해, 동일한 평면에서의 색 왜곡현상 (color distortion) 문제가 발생한다.

본 논문에서는 이러한 문제를 극복하기 위해, 영상의 색상 왜곡을 막으면서 저조도 영상을 개선할 수 있는 새로운 손실 함수를 제안하였다.

본 논문의 나머지 구성은 다음과 같이 구성되어있다. 2 장에서는 제안하는 손실 함수에 대한 설명과 함께, 정량적, 정성적 실험결과를 설명하고 3 장에서 본 논문을 마무리한다.

### II. 본론

제안하는 손실 함수는  $L_1$  loss 에 SSIM loss ( $L_{SIMM}$ )와

Color correction loss ( $L_{CC}$ )를 추가하여 구성하였고, 이를 입력 영상과 GT 영상 사이에 적용하여 학습을 진행하였다.

입력 영상과 GT 영상과의 차이에 해당하는  $L_1$  loss 는 아래와 같다.

$$L_1 = \sum_{p \in P} |y(p) - \hat{y}(p)| \quad (1)$$

$L_{SIMM}$  의 경우, 아래와 같이 서로 다른 두 영상의 시각적 화질 차이와 유사한 정도를 평가하기 위해 휘도 (luminance), 대비 (contrast), 구조 (structure) 측면을 수치화한 SSIM (structural similarity index)[5]을 활용하여 얻어진다.

$$L_{SIMM}(p) = \sum_{p \in P} (1 - SSIM(y(p), \hat{y}(p))) \quad (2)$$

$L_{CC}$  의 경우는 이미지의 x-방향, y-방향으로 변화하는 정도를 측정하는 Image gradient 를 YUV 컬러 모델에 적용하였다. 식 (3)과 같이 동일 표면에서는 변화가 심한 U 채널, V 채널의 gradient 를 분자에 놓고, 변화가 적은 Y 채널을 분모로 하는 손실 함수를 정의하여, Y 채널의 변화가 적은 곳인데, U 채널 또는 V 채널의 변화가 많이 생긴 경우, 이를 개선하는 방향으로 학습될 수 있도록 손실 함수를 설계하였다. 여기서  $Y(p)$ ,  $U(p)$ ,  $V(p)$ 는

image patch 의 Y, U, V 채널을 각각 나타내고,  $\nabla(\cdot)$ 는 gradient operation 을 나타낸다.

$$L_{cc} = \sum_{p \in P} \frac{\nabla U(p) + \nabla V(p)}{\nabla Y(p)} \quad (3)$$

하여 최종적인 Total loss ( $L_{total}$ )은 식 (4)와 같이 parameter ( $\alpha$ ,  $\beta$ )을 선형결합하여 구성하였고, 실험적으로 (0.5,  $10^{-3}$ )의 값으로 결정되었다.

$$L_{total} = L_1 + \alpha * L_{SSIM} + \beta * L_{CC} \quad (4)$$

최종 손실 함수 ( $L_{total}$ )를 통해 보편적으로 중단간 학습에 사용되는 Encoder-Decoder 형태를 가진 모델인 U-net 을 네트워크를 학습하였다. 네트워크의 학습 (Training)과 성능 평가는 Chen 의 SID Sony 이미지 센서 (a 7S-II) 데이터셋[6]을 사용하였다.

제안한 손실 함수를 통해 얻어낸 출력 영상의 정량 평가는 크게 신호가 가질 수 있는 최대 신호에 대한 잡음의 비를 나타내는 PSNR (Peak Signal-to-Noise Ratio)과 SSIM (structural similarity index)[5], 2 가지로 기존 방법과 비교했다. 그 결과는 표 1 과 같으며 기존 방식 (Chen[4])보다 개선된 성능을 확인할 수 있다.

정성 평가의 경우, 제안하는 방법으로 얻은 결과 영상을 기존 방법과 시각적으로 비교하였다. 그림 1 을 보면, 기존 방법을 통해 얻은 결과 영상에는 계시물 사이 얼룩과 같이 색 왜곡 현상이 발생하는 것과 달리, 제안하는 방법은 이와 같은 현상을 개선한 결과를 생성하는 것을 확인할 수 있다.

Method	Chen[4]	Ours
PSNR	31.91	31.96
SSIM	0.783	0.787

표 1. 성능 정량 평가 결과



그림 1. 정성 평가 샘플 영상 비교 (GT/ Chen[4]/ Ours)

### III. 결론

본 논문은 극저조도 환경의 노이즈 영상 개선을 위한 손실 함수를 제안하였다. 기존 방식에서 드러난 색 왜곡 현상의 문제를 개선하기 위해 기존 방식의 L1 loss 에 SSIM loss 와 Image gradient 를 활용한 Color correction loss 를 추가하여 손실 함수를 설계하였다. 정량적, 정성적 평가를 통해 기존 방식보다 좀 더 개선된 영상을 얻어낼 수 있음을 확인하였다.

### ACKNOWLEDGMENT

This work was supported by Institute for Information & communications Technology Promotion (IITP) grant funded by the Korea government(MSIT) (No.2019-0-00268, Development of SW technology for recognition, judgment and path control algorithm verification simulation and dataset generation).

### 참 고 문 헌

- [1] X. Guo, Y. Li, and H. Ling, "Lime: Low-light image enhancement via illumination map estimation," IEEE Trans. Image Process., vol. 26, no. 2, pp. 982-993, Feb. 2017
- [2] K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian, "Image denoising by sparse 3-D transform-domain collaborative filtering," IEEE Trans. Image Process., vol. 16, no. 8, pp. 2080-2095, Aug. 2007.
- [3] R. Wang, Q. Zhang, C. W. Fu, X. Shen, W. S. Zheng, and J. Jia, "Underexposed Photo Enhancement Using Deep Illumination Estimation," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun. 2019, pp. 6849-6857.
- [4] C. Chen, Q. Chen, J. Xu, and V. Koltun, "Learning to see in the dark," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), May. 2018, pp. 3291- 3300.
- [5] Zhou, W., A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image Quality Assessment: From Error Visibility to Structural Similarity," IEEE Trans. Image Process., vol. 13, no. 4, pp. 600- 612, Apr. 2004.
- [6] <https://github.com/cchen156/Learning-to-See-in-the-Dark>