

건설현장 내 객체 검출 정확도 향상을 위한 저조도 영상 강화 기법에 관한 연구

오해인, 나종호, 신휴성

한국건설기술연구원 미래스마트건설연구본부

e-mail: haeinoh@kict.re.kr, najongho@kict.re.kr, hyushin@kict.re.kr

A Study on Low-Light Image Enhancement Technique for Improvement of Object Detection Accuracy in Construction Site

Hae-In Oh, Jong-Ho Na, Hyu-Soung Shin

Dept. of Future and Smart Construction Research, Korea Institute of Civil Engineering and Building Technology

요약

공사 현장의 안전관리를 위한 모니터링 시스템은 예상치 못한 위험 요인 감지를 위해 특수 기상 조건 및 다양한 조도 환경에도 안정적으로 운용 가능하여야 한다. 저조도 환경에서는 영상에 존재하는 객체의 검출 정확도가 매우 떨어지므로, 저조도 영상을 밝게 변환시키는 영상 전처리 기술의 필요성이 대두된다. 본 논문에서는 복수개의 딥러닝 기반의 저조도 영상 강화 모델(GLADNet, KinD, LLFlow, Zero-DCE)을 활용해 택지개발 공사 현장 영상의 저조도 배경을 밝게 변환하는 실험을 진행하였다. 각 모델마다 강화된 조도 영상을 시각적으로 분석하고 영상품질 평가 지수인 PSNR, SSIM, Delta-E로 수치 분석을 수행하였다. 실험 결과, GLADNet의 저조도 강화 성능이 정량적, 정성적 측면에서 가장 우수한 것으로 분석되었다. 향후 딥러닝 기반의 저조도 영상 강화 모델이 건설 현장 객체 검출 모델의 전처리 단계에 적용된다면, 저조도 환경에서도 우수한 성능의 객체 검출이 가능할 것이라 기대된다.

1. 서론

성적, 정량적으로 분석하였다.

2. 딥러닝 기반의 저조도 영상 강화 기법


최근 정부는 산업안전보건법 및 중대재해처벌법 제정을 통해 산업현장의 사망 및 안전사고 대응을 지속적으로 강화하고 있다[1]. 이에 따라 사업장 내의 위험 요인을 사전에 발견하여 중대재해를 대비할 수 있는 딥러닝 기반의 안전관리 시스템에 많은 연구자들의 관심이 집중되고 있다. 한국건설기술연구원은 실제 택지개발 공사현장 확보를 통해 CCTV 현장 영상 데이터를 취득하였으며 건설 현장 내 취득 가능한 주요 객체를 정의하고 객체 검출을 진행한 바 있다[1]. 객체 검출 모델은 끊임없는 현장 추적과 위험 요인의 안정적인 감지를 위해서 주변 배경 환경의 변화에도 강인해야 한다. 하지만, 저녁시간이나 흐린 날씨로 인한 저조도 환경에서의 객체 검출 정확도는 밝은 조도 조건에서의 객체 검출 정확도에 비해 현저히 낮아진다. 이에 따라, 본 연구에서는 저조도 환경에 대응력이 좋은 객체 검출 모델을 생성하기 위한 전처리 과정의 일환으로 저조도 영상을 밝은 조도 영상으로 변환하는 실험을 진행하였다. 저조도 환경에서 취득한 택지개발 공사현장 CCTV 영상을 복수개의 딥러닝 기반 저조도 영상 강화 모델들에 적용하였으며, 각 모델마다 저조도 영상 강화 결과를 정

최근 컴퓨터 비전 분야에서 딥러닝을 이용한 영상 처리 기법의 적용이 활성화되고 있다. 이에 따라 통계값이나 Retinex 원리에 기반한 전통적인 저조도 영상 강화 기법에 딥러닝을 도입하는 방안이 활발히 모색되고 있다[2].

딥러닝 기반의 저조도 영상 강화 기법은 데이터 학습 방식의 측면에서 지도학습을 적용한 기법과 비지도 학습을 적용한 기법으로 구분된다. 지도학습은 다량의 정답 데이터(labeled data)를 학습한다. 따라서 저조도와 일반 조도 영상이 일대일로 대응하는 데이터 쌍을 학습 데이터로 사용하며 일반 조도 영상을 정답 데이터로 활용한다. 반면에, 비지도 학습은 정답이 없는 데이터에서 패턴을 추론하므로, 데이터 쌍을 필요로 하지 않는다. 본 논문에서 적용한 GLADNet[3], KinD[4], LLFlow[5]는 지도학습 방식을 따르고 있으며, Zero-DCE[6]는 비지도 학습 방식을 따르고 있다.

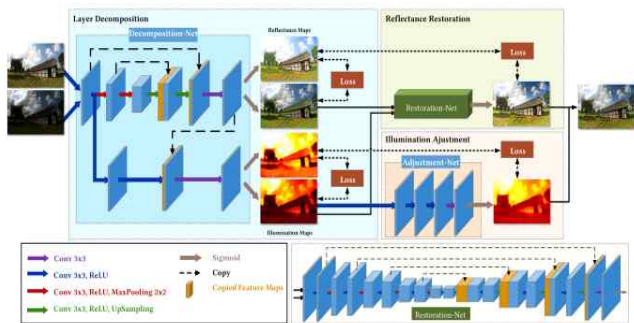
그림 1은 GLADNet의 모델 흐름도이다. GLADNet은 global illumination estimation 단계와 details reconstruction

단계로 구성되어 있다. 1단계에서는 저조도 영상에 대한 영상 전역의 일반 조도를 추정하며, 2단계에서는 1단계에서 손실된 영상의 상세정보를 복원한다[3].



[그림 1] GLADNet 모델 흐름도[3]

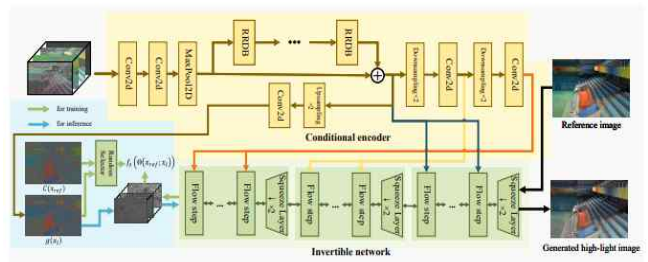
그림 2는 KinD의 모델 흐름도이다. KinD는 layer-decomposition net, illumination adjustment net, reflectance restoration net로 구성되어 있다. 1단계에서는 저조도 영상과 일반 조도 영상을 reflectance 성분과 illumination 성분으로 분해한다. 2단계에서는 저조도 영상의 illumination과 일반 조도 영상의 illumination 간의 비율을 계산하고 이를 이용하여 저조도 영상의 조도를 강화한다. 3단계에서는 일반 조도 영상의 reflectance를 참조하여 저조도 영상의 reflectance와 강화된 저조도 영상의 illumination을 합성한다[4].




[그림 2] KinD 모델 흐름도[4]

그림 3은 LLLflow의 모델 흐름도이다. LLLflow는 인코더 단계와 가역 네트워크 단계로 구성되어 있다. 1단계에서는 저조도 영상으로부터 color map을 출력한다. 2단계에서는 획득한 color map을 일반 조도 영상과 연결하는 가역적 정규화 흐름을 통하여 저조도 영상을 강화한다[5].

그림 4는 Zero-DCE의 모델 흐름도이다. Zero-DCE는 Light-Enhancement curves(LE-curves)와 Deep Curve Estimation Network(DCE-Net)으로 구성되어 있다. DCE-Net은 저조도 영상 픽셀이 가진 모든 RGB 채널을 입력으로 받아서 각 채널에 대응하는 고차원 LE-curves를 출력한다. 출력된 LE-curves는 저조도 영상에 적용된다. 이 과정은 최종 저조도 강화 영상이 출력될 때까지 반복된다[6].



[그림 3] LLLflow 모델 흐름도[5]



[그림 4] Zero-DCE 모델 흐름도[6]

본 논문에서는 딥러닝 기반의 최신 저조도 강화 모델인 GLADNet, KinD, LLLflow, Zero-DCE를 활용하여 실제 토공 현장에서 취득한 어두운 배경의 영상 데이터를 밝은 조도의 배경으로 변환하는 영상 강화 실험을 진행하였다. 또한, 각 모델의 특성을 파악하기 위해 정량적, 정성적 평가 분석을 수행하였다.

3. 저조도 강화 실험

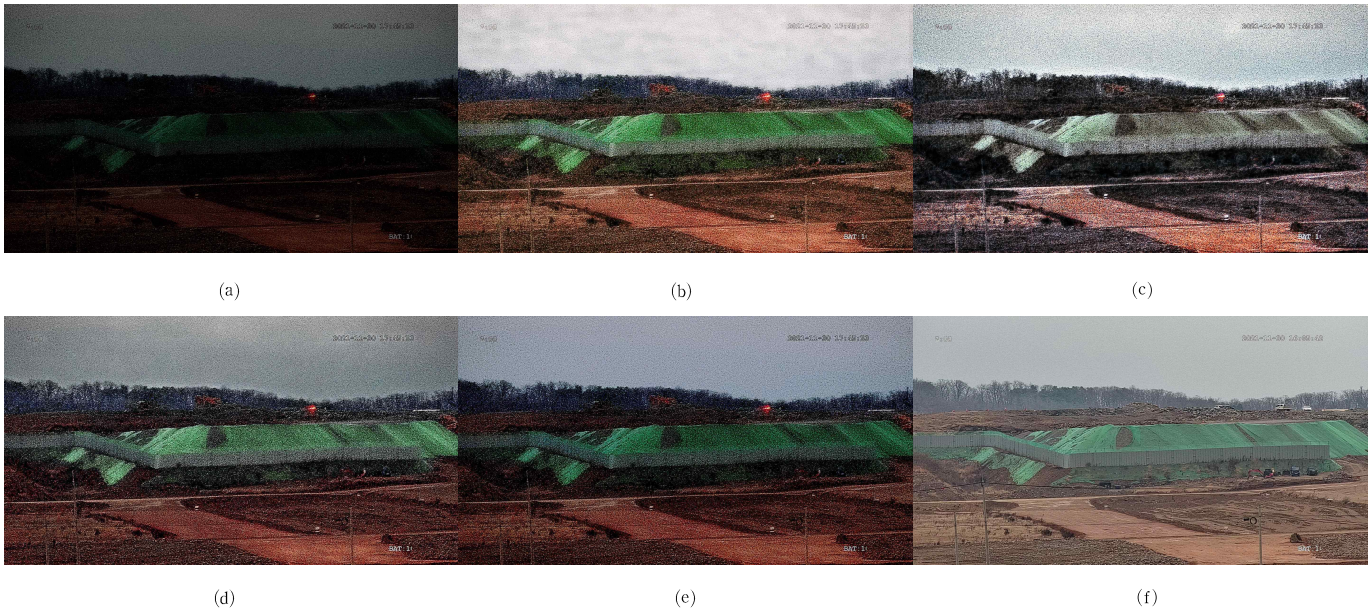
3.1 실험 데이터

본 연구는 실험 데이터로 한국건설기술연구원에서 택지개발 공사현장 확보를 통해 취득한 CCTV 영상[1]을 사용하였다. 해당 원천 영상은 2021년도에 약 9개월 동안 취득한 데이터이며, 실제 실험을 위해 사용된 데이터는 동절기에 해당하는 1개월 동안 오후 5시에서 6시 사이의 저조도 영상을 추출하여 구성하였다. 다음 표 1은 저조도 정지영상과 일반 조도 정지영상 현황을 나타내며, 저조도 영상과 일반 조도 영상이 각각 대응되도록 데이터를 구성하였다.

[표 1] 저조도 및 일반조도 정지 영상 현황

Month(월)	저조도 정지영상 개수	일반조도 정지영상 개수
11월	366	366
12월	104	104
	420	420

실험에 사용된 모델은 지도학습과 비지도 학습으로 구분되므로, 학습 모델의 특성을 고려하여 학습 데이터셋을 구성해



[그림 5] 저조도 영상 강화 결과 비교: (a) low light image, (b) GLADNet[3], (c) KinD[4], (d) LLFlow[5], (e) Zero-DCE[6], (f) normal light image.

야 한다. 다음 표 2는 각 모델의 데이터셋 구성 현황을 나타낸다. 지도학습 모델인 GLADNet, KinD, LLFlow은 학습 데이터셋을 저조도 정지영상과 일반 조도 정지영상의 쌍으로 구성하였다. 비지도 학습 모델인 Zero-DCE는 학습 데이터셋을 저조도 정지영상과 일반 조도 정지영상이 합쳐진 멀티 조도 (multi-exposure) 영상으로 구성하였다.

[표 2] 데이터셋 구성

모델	데이터셋 종류	데이터 구성	개수
GLADNet	train	저조도 정지영상	376
KinD		일반조도 정지영상	376
LLFlow	train	멀티조도 정지영상	752
Zero-DCE		test	저조도 정지영상

3.2 실험 방법

앞서 구성한 학습 데이터셋을 이용하여 각각의 저조도 강화 모델 학습을 수행하고 모델을 생성하였다. 이후에 테스트 데이터셋을 이용하여 학습된 모델에 대한 추론을 진행하였으나 학습 데이터의 부족으로 성능이 좋지 않음을 확인하였다. 이에 따라 학습된 모델 대신에 기 학습된 모델로 추론하고 결과를 분석하였다.

3.3 실험 결과 및 분석

각 저조도 강화 모델의 효과를 정성적으로 비교하기 위하여 강화된 저조도 영상에 대한 육안 분석을 수행하였다. 또한, 정량적인 비교를 위하여 일반 조도 영상에 대한 저조도 강화 영상의 영상 품질 평가 지수를 산출하고 분석하였다.

3.3.1 육안 분석

그림 5-(a)는 저조도에서 촬영한 토공현장 원본 영상이며, 그림 5-(b)에서 그림 5-(e)는 각 저조도 강화 모델 적용 결과이고, 그림 5-(f)는 일반 조도에서 촬영한 토공현장 원본영상이다. 시각적으로 분석한 결과 각각의 저조도 영상 강화 모델을 통해 영상의 조도가 강화된 것을 확인할 수 있다. 지도 학습 기반의 저조도 강화 모델인 GLADNet, KinD, LLFlow 모두 Retinex 원리를 따르지만 결과는 상이하게 나타났다. KinD의 적용 결과, 영상의 전반적인 조도는 강화되었지만 회색조로 표현되었다. LLFlow와 GLADNet의 적용 결과는 상대적으로 전체 픽셀 고유의 reflectance 성분과 illumination 성분이 일반 조도에 가깝게 복원되었다. 또한, GLADNet의 적용 결과에서는 영상의 전체적인 대비가 향상되었다. 비지도 학습 기반의 저조도 강화 모델인 Zero-DCE의 적용 결과에서는 상대적으로 잡음이 제거되었지만 영상이 청색으로 표현되는 색감 왜곡 현상이 발생하였다.

3.3.2 영상 품질 평가 지수

영상품질 평가 지표로 PSNR(Peak-Signal-to Noise Ratio), SSIM(Structural Similarity), Delta-E를 사용하였다. 다음 표 3은 모든 저조도 강화 모델의 영상 품질 평가 지수 결과를 보여준다. 모든 모델의 영상 품질 평가 지수가 개선되었음을 볼 수 있다.

PSNR은 영상신호가 가질 수 있는 최대 신호 크기 대 잡음의 비로 정의되며, PSNR이 높은 영상은 품질이 우수한 영상으로 평가된다. GLADNet은 강화된 저조도 영상의 PSNR이 11.506으로 품질이 가장 우수한 것으로 나타났다. SSIM은 인간의 시각적 기관의 작동 원리에 기반한 품질 평가 지수이며,

[표 3] 저조도 강화 모델을 적용한 영상의 영상 품질 평가 지수

	PSNR ↑	SSIM ↑	Delta-E ↓
Low light	8.362	0.043	38.022
GLADNet	11.506	0.057	8.034
KinD	10.878	0.053	1.225
LLFlow	10.771	0.049	14.257
Zero-DCE	10.672	0.050	23.151

SSIM이 높은 영상은 품질이 우수한 영상으로 평가된다. GLADNet으로 강화된 저조도 영상의 SSIM이 0.057로 품질이 가장 높다고 분석되었다. Delta-E는 영상의 색상 품질을 평가하는 지수이다. Delta-E가 0에 근접할수록 색상 품질이 우수한 영상으로 평가된다. KinD로 강화된 저조도 영상의 Delta-E가 1.225로 색상 품질이 가장 높은 것으로 분석된다. 육안 분석 결과 KinD로 강화된 저조도 영상의 조도가 가장 낮았기 때문에 Delta-E는 인간이 시각적으로 인지하는 영상 품질을 제대로 반영해주지 못함을 알 수 있었다.

테스트 데이터셋에 대한 각 모델의 저조도 강화 영상을 정성적, 정량적으로 분석한 결과 GLADNet의 영상 품질이 가장 높다는 것을 알 수 있다.

4. 결론

본 논문에서는 저조도 환경에서 취득한 토공현장 영상의 조도를 디러닝 기반의 영상 강화 모델을 통해 강화하는 연구를 진행하였다. 실제 택지개발 공사현장의 CCTV 영상에서 저조도 영상과 일반 조도 영상을 선별하여 데이터셋을 구축하였으며, 저조도 영상 강화 모델인 GLADNet, KinD, LLFlow, Zero-DCE를 통해 테스트 데이터셋에 대한 저조도 강화를 진행하고 각 모델의 결과를 분석하였다. 실험 결과, 모든 저조도 강화 모델에서 영상의 조도가 강화된 것을 확인하였다. 육안 분석 결과, GLADNet이 전체적인 대비가 향상되었으며 일반 조도 영상과 가장 유사하게 강화된 영상을 출력한 것을 확인하였다. 평가지표를 통한 정량적 분석 결과, GLADNet의 총체적인 품질 평가 지수가 가장 많이 개선되어 GLADNet으로 강화된 영상의 품질이 가장 높은 것을 확인하였다. 이에 따라 GLADNet이 보유한 토공현장 데이터셋의 저조도 강화에 가장 효과적인 것으로 분석되었다. 본 연구는 저조도 환경에서 취득한 건설 현장 내 CCTV의 조도를 강화하는 전처리 과정으로 활용 가능하며, 건설 현장 내 주요 객체의 검출 정확도를 높이는 데 기여할 것으로 기대된다. 향후 연구에서는 저조도 영상과 저조도 강화 영상 간의 객체 검출 정확도를 비교하고 분석하여 객체 검출 모델의 전처리 단계로서의 저조도 강화 효과를 검증할 예정이다.

감사의 글

본 연구는 과학기술정보통신부 한국건설기술연구원 주요 사업으로 지원을 받아 수행된 연구((22주요-대2-BIG)극한건설 환경 구현 인프라 및 TRL6 이상급 극한건설 핵심기술 개발 (7/9))로 이에 감사드립니다.

참고문헌

- [1] 나종호, 추연, 윤일동, 신휴성. (2022). 건설현장 내 주요객체 영역분할 성능 향상 기법에 관한 연구. 한국산학기술학회 춘계 학술발표논문집, 983-986.
- [2] 이화선, 박재민, 홍성철, & 신휴성. (2020). 달 영구음영지역의 지형정보 구축을 위한 저조도 지형 영상 강화. 대한공간정보학회지, 28(4), 41-48.
- [3] Wang, W., Wei, C., Yang, W., & Liu, J. (2018, May). Gladnet: Low-light enhancement network with global awareness. In 2018 13th IEEE international conference on automatic face & gesture recognition (FG 2018) (pp. 751-755). IEEE.
- [4] Zhang, Y., Zhang, J., & Guo, X. (2019, October). Kin-dling the darkness: A practical low-light image enhancer. In Proceedings of the 27th ACM international conference on multimedia (pp. 1632-1640).
- [5] Wang, Y., Wan, R., Yang, W., Li, H., Chau, L. P., & Kot, A. (2022, June). Low-light image enhancement with normalizing flow. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 36, No. 3, pp. 2604-2612).
- [6] Guo, C., Li, C., Guo, J., Loy, C. C., Hou, J., Kwong, S., & Cong, R. (2020). Zero-reference deep curve estimation for low-light image enhancement. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 1780-1789).