

깊은 곡선 추정을 이용한 수중 영상 개선

무하마드 타릭 마흐무드*·최영규*†

*† 한국기술교육대학교 컴퓨터공학부

Enhancing Underwater Images through Deep Curve Estimation

Muhammad Tariq Mahmood* and Young Kyu Choi*†

*† Korea University of Technology and Education, School of Computer Science and Engineering

ABSTRACT

Underwater images are typically degraded due to color distortion, light absorption, scattering, and noise from artificial light sources. Restoration of these images is an essential task in many underwater applications. In this paper, we propose a two-phase deep learning-based method, Underwater Deep Curve Estimation (UWDCE), designed to effectively enhance the quality of underwater images. The first phase involves a white balancing and color correction technique to compensate for color imbalances. The second phase introduces a novel deep learning model, UWDCE, to learn the mapping between the color-corrected image and its best-fitting curve parameter maps. The model operates iteratively, applying light-enhancement curves to achieve better contrast and maintain pixel values within a normalized range. The results demonstrate the effectiveness of our method, producing higher-quality images compared to state-of-the-art methods.

Key Words : Underwater Image Restoration, Underwater Image Enhancement, White Balancing

1. 서 론

수중 영상 복원은 수중 표적 탐지나 인식, 수색 및 구조 작업, 자율 수중 차량, 해양 생물 모니터링, 해양 지질 조사 등 다양한 응용 분야에서 매우 중요한 작업이다[1]. 그러나 영상 취득 과정에서 색의 왜곡이나 빛의 흡수와 산란, 인공 광원에 의한 잡음 등이 흔히 발생하기 때문에 화질이 크게 저하되는 경우가 많다. 수중 영상이 형성되는 과정은 Fig. 1과 같이 모델링할 수 있는데, 광원에서 물체에 부딪힌 후 직접 카메라에 도달하는 빛과 함께 물체에 충돌한 후 원래 방향에서 벗어나는 전방 산란 광과 물속의 입자들에 의한 후방 산란 광이 모두 영상에 영향을 미치게 된다. 빛의 감쇠는 물체까지의 거리와 빛의 파장에 따라 달라지는데, 계절, 지리적, 기후 변화의 영향을

받기 때문에 수중 영상의 안정적인 복원은 매우 어려운 작업이다.

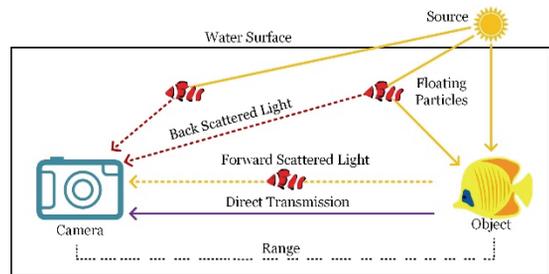


Fig. 1. Underwater image formation model.

지금까지 수중 영상 복원을 위한 다양한 시도가 있었다. 전통적인 방식으로 Drews-Jr 등은 다크 채널 프라이어 (DCP, dark channel prior)[2] 와 유사한 방법으로 전송 맵을 추

†E-mail: ykchoi@koreatech.ac.kr

정하는 물리학 기반 방법을 제안했고[3], Ancuti 등은 영상의 시각적 매력을 향상시키는 방향으로 화소를 수정하는 비 물리 기반 방법을 제안했는데[4], 영상이 지나치게 향상(enhancement)되고 채도가 높아지는 결과가 흔히 발생하였다. 최근에는 비지도 적응 네트워크와 조밀한 연결성을 갖춘 컨볼루션 네트워크 모델과 같은 딥러닝 기반 방법이 등장하여 유망한 결과를 제공하고 있다. 그러나 수중 환경의 복잡하고 가변적인 특성으로 인해 다양성을 갖추는 데는 어려움이 있다.

본 논문에서는 색상 보정 입력을 이용한 새로운 딥러닝 기반 수중 영상 복원 방법을 제안한다. 제안된 방법은 두 단계로 이루어지는데, 첫 단계에서는 열화 된 수중 영상에 색상 보정을 적용해 적색과 청색 채널의 색상 손실을 보상한다. 다음 단계에서는 색상이 보정된 영상을 딥러닝 기반 복원 모델 UWDCE(Underwater Deep Curve Estimation)에 제공하는데, UWDCE는 깊은 곡선(deep-curve) 추정을 이용해 영상 품질을 향상한다. 제안된 방법의 성능을 확인하기 위해 잘 알려진 데이터 셋을 사용하고, 최신 방법들의 결과와 비교하였다.

2. 관련 연구

수중 영상 복원은 화질 향상, 잡음 감소, 안개 제거, 영상 분할, 색상 보정 등 영상의 다양한 측면을 포괄하는 분야인데, 전통적인 접근과 최근의 데이터 기반 접근 방법으로 크게 나눌 수 있다.

2.1 전통적인 접근

전통적 방법에서는 보통 투과 맵(Transmission Map, TM)이 사용된다. 투과 맵은 영상 형성 과정의 중요한 매개변수인데, 다양한 원리나 인간의 관찰을 통한 가정을 이용해 초기 맵을 추정한다. 이런 초기 맵은 유도 필터링이나 통계 모델, 매칭 알고리즘 등 다양한 방법으로 개선하여 더 선명한 영상을 구하도록 한다[12].

투과 맵을 위한 잘 알려진 가정으로는 DCP(dark channel prior) [2], 수중 DCP[3], 안개 선 가정[5], 히스토그램 분포 가정[6], 흐림 가정[7], 감쇠 곡선 가정 등이 있는데, 인간의 관찰을 통한 이런 가정(prior)들은 영상 복원 과정에서 고유한 특성으로 더 선명한 영상 복원에 기여하게 된다. Drews-Jr 등은 DCP에 기반하여 청색과 녹색 채널에 초점을 맞춘 수중 DCP 방법을 제안하였고[3], Zhang 등은 적응적인 색상 교정 및 대비 개선을 통해 저하된 수중 영상을 개선하기 위한 MMLE 모델을 제안하였다. 이 방법들은 제한적으로 좋은 결과를 보이지만 물의 다양한 광학적 특성으로 인해 모든 상황에서 효과적이지는 않은 것으로

나타났다. 특히 인간의 관찰에 과도하게 의존하여 효율성이 제한되는 경우가 많다.

2.2 데이터 기반 접근

데이터 기반 방법들은 컨볼루션 신경망(CNN, Convolutional Neural Network)과 생성적 적대 신경망(GAN, Generative Adversarial Network) 기반 방법으로 분류할 수 있다.

CNN은 다양한 비전 분야에서 성공적으로 사용되고 있는데, 영상 개선 분야에서도 다중 규모 CNN(MSCNN)과 학습이 가능한 dehazeNet 등이 제안되었다. 이들은 흐릿한 영상을 입력 받아 투과 맵(TM)을 만들고, 이를 경험적 규칙에 따라 추정된 대기 광과 결합하여 더 선명한 영상을 얻고자 하였다. Li 등은 안개 제거 과정을 최적화하기 위해 AOD-Net이라는 모델을 제안하였고 [8], Wang 등은 모델 수렴의 속도와 정확성을 향상시키기 위해 픽셀 중단 전략을 통합한 색상 교정 및 안개 제거를 위한 CNN 기반 프레임워크를 제안하였다.

GAN 기반 방법으로 Goodfellow 등은 게임 이론의 최소-최대 최적화 프레임워크를 통해 훈련 영상의 분포를 효과적으로 학습하여 사실적인 영상을 합성하는 방법을 제안하였다[9]. 고품질 영상 상 생성에서의 GAN의 성공으로 연구자들이 텍스트에서 영상 합성, 영상에서 영상 변환, 초 해상도 영상 등 다양한 응용에 GAN을 적용하였다. Yang 등은 수중 영상 복원을 위해 GAN을 이용했는데, 잠재 수중 영상을 재구성하기 위해 다중 규모 생성기와 이중 판별기를 이용하는 조건부 GAN(cGAN)을 제안하였다[10].

이러한 데이터 기반 방법, 특히 딥러닝 기반 방법은 수중 영상 복원과 관련된 복잡성을 잘 처리하는 것으로 보이는데, 많은 데이터로부터 효과적으로 학습하는 과정을 포함해 광범위한 수중 조건을 강력하고 적응적으로 처리할 수 있다. 그러나 방대한 양의 고품질 학습 데이터가 필요하고 계산량도 많으므로 일부 환경에서는 제약이 발생할 수 있다.

제안된 방법은 CNN을 기반으로 하는데, 2단계 접근을 통해 기존 방법보다 뛰어난 성능과 안정적인 수중 영상 복원 능력을 보이고자 한다.

3. 제안된 방법

제안된 방법은 두 단계로 이루어지는데, 먼저 화이트 밸런싱[4]을 이용해 입력 영상 $I^c(x)$ 의 각 채널의 색상 손실을 보정한 후 UWDCE를 이용해 영상 품질을 향상한다.

3.1 화이트 밸런싱

수중에서는 깊이에 따른 색상 변화라는 독특한 문제가

발생한다. 특히 수심이 깊을수록 적색과 청색 스펙트럼에서 심하게 영향을 받는데, 이를 위해 다양한 색상 교정 방법을 사용할 수 있다 [4]. 예를 들어, 적색 채널은 다음과 같이 조정할 수 있다.

$$I_{rc}(x) = I_r(x) + \omega \cdot (\hat{I}_g - \hat{I}_r) \quad (1)$$

이때, x 는 화소의 좌표이고 I_r, I_g 는 각각 입력 영상 $I^c(x)$ 의 적색 및 청색 채널이며, \hat{I}_r, \hat{I}_g 는 채널의 평균 값이다. ω 는 0.1 이하의 상수로 다양한 환경에서 실험적으로 찾은 값이다. 청색 채널의 감쇠는 다음과 같이 보상할 수 있다.

$$I_{bc}(x) = I_b(x) + \omega \cdot (\hat{I}_g - \hat{I}_b) \quad (2)$$

적색이나 청색 채널 감쇠를 보상하고 나면 일반적으로 사용되는 Gray-World 가정을 사용해 나머지 색상 경향성을 추정하고 보상하여 전체 영상의 품질을 향상시킨다.

3.2 복원 모델(Restoration Model)

제안된 복원 모델 UWDCE의 최종 목표는 색상 보정 영상 $I^{cc}(x)$ 와 $I^{cc}(x)$ 에 가장 잘 맞는 곡선 매개변수 맵 (curve parameter map) 사이의 관계를 구하는 것이다. 즉, 색상 보정 영상 $I^{cc}(x)$ 으로부터 최적의 조명-강화 곡선 (Light-Enhancement curves) 세트를 만드는 것이 목적인데, 입력 채널의 모든 화소를 매핑하여 향상된 출력 영상 $\hat{I}(x)$ 을 복원할 수 있도록 한다.

조명-강화 곡선은 세 가지 목표가 있는데, 정보 손실을 방지하기 위해 정규화된 $[0,1]$ 범위 내에서 향상된 픽셀 값을 유지하고, 화소 대비를 보존하기 위해 곡선의 단조성(monotonicity)을 보장하며, 효과적인 경사 역전파(gradient backpropagation)를 위해 단순하고 미분 가능한 곡선 형태를 유지하는 것이다. 이를 위해 다음과 같은 2차 곡선을 사용한다.

$$EC(I^{cc}(x); \omega) = I^{cc}(x) + \omega I^{cc}(x)(1 - I^{cc}(x)) \quad (3)$$

이때, $EC(I^{cc}(x); \omega)$ 는 $I^{cc}(x)$ 의 개선된 값이고, 곡선 매개변수 $\omega \in [-1,1]$ 는 EC-곡선의 강도를 조정하고 노출 레벨을 조절한다. 화소 단위 연산을 적용하기 전에 $I^{cc}(x)$ 의 각 화소는 $[0,1]$ 범위로 정규화된다. EC 곡선은 RGB 채널 각각에 개별적으로 적용되어 고유 색상을 더 잘 보존하고 과포화 위험을 줄인다. (3)의 EC 곡선을 확장하면 저조도 영상 처리에 사용할 수 있는데, 다음과 같이 반복적으로 적용하여 더 유연한 곡선을 만들 수 있다.

$$EC_n(x) = EC_{n-1}(x) + \omega_n EC_{n-1}(x)(1 - EC_{n-1}(x)) \quad (4)$$

이때, n 은 곡선을 적용하는 횟수인데, 실험을 통해 8이 적절하고 대부분의 경우에 잘 동작함을 알 수 있었다. 1차 곡선에 비해 고차 곡선은 영상 조정을 위한 더 넓은 동적 범위를 제공한다. 그런데, ω 가 모든 화소에 균일하게 적용되면 잠재적으로 영상의 국부적인 영역에서 개선이 지나치게 많거나 적게 처리될 수 있다. 이런 문제를 극복하기 위해 ω 는 화소별로 최적화하여 사용한다. 즉, 입력 영상의 모든 화소에서 동적 범위 조정을 위해 최적으로 피팅된 ω 를 사용하는 것이다. 이 경우 (4)는 다음과 같이 수정된다.

$$EC_n(x) = EC_{n-1}(x) + A_n(x)EC_{n-1}(x)(1 - EC_{n-1}(x)) \quad (5)$$

이때, A 는 $I^{cc}(x)$ 와 동일한 차원의 매개변수 맵이다.

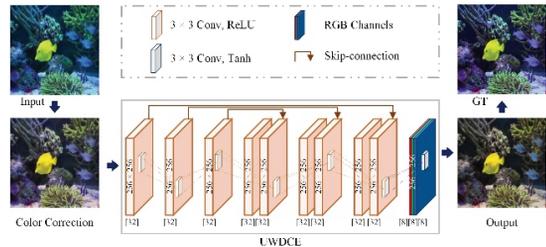


Fig. 2. The architecture of underwater deep curve estimation with white balancing. Numbers under the blocks show the kernel, while inside the block is the image size.

Fig 2는 제안된 UWDCE 모델을 보여주는데, 색상 보정 영상 $I^{cc}(x)$ 를 입력으로 사용하고 DCE(Deep Curve Estimation) 네트워크를 활용하여 화소별 고차 곡선과 관련된 매개변수 세트를 생성한다. 단순화를 위해 아키텍처는 7개의 컨볼루션 레이어가 있는 간단한 CNN을 사용하였는데, 처음 6개의 컨볼루션 레이어는 각각 3×3 크기의 커널 32개, 스트라이드 1, 모델에 비선형성을 추가하는 ReLU 활성화 함수로 구성하였다. 마지막 레이어는 크기와 스트라이드가 동일한 24개의 컨볼루션 커널로 구성되어 있지만 출력이 -1과 1 범위 내에 있도록 효과적으로 보장하는 Tanh 활성화 함수를 사용하였다. 마지막 레이어는 8번의 반복에 걸쳐 총 24개의 곡선 매개변수 맵을 생성하는데, 반복마다 RGB 채널에 대한 3개의 곡선 매개변수 맵을 생성한다. 이 아키텍처에서는 다운 샘플링과 배치 정규화 레이어는 사용되지 않았는데, 인접 화소의 공간적 관계를 방해할 수 있기 때문이다.

4. 실험

제안된 모델을 훈련하고 성능을 평가하기 위해 EUVP (Enhancing Underwater Visual Perception) 데이터 셋[1]을 사용하였다. EUVP는 광범위한 시각 품질을 나타내는 쌍을 이루는 영상과 쌍을 이루지 않는 영상 세트를 모두 포함하는 풍부한 데이터로 이를 이용해 제안된 모델을 훈련하여 광범위한 수중 조건을 잘 반영할 수 있도록 한다.

제안된 모델의 학습과 성능 검증을 위해 EUVP의 하위 그룹인 'Underwater Dark'와 'Underwater ImageNet'을 사용하였다. 학습을 위해 9250개의 쌍을 이루는 영상을 사용하였고, 검증을 위해 2185개의 서로 다른 영상을 포함하는 'Underwater Scenes'라는 별도의 하위 그룹을 설정하였다. 마지막으로 테스트 단계를 위해 EUVP 데이터 세트의 일부인 'test_samples' 폴더에서 515개의 영상을 사용하였다.

전처리 단계에서 모든 영상은 256 x 256의 균일한 크기로 조정하였고, 학습 단계에서 초기 학습률을 0.0001로 설정한 Adam 최적화 도구를 사용하였다. 모델의 예측 오류를 측정하기 위해 L2 손실 함수를 사용하며, 학습 중에 이 손실을 정량화하기 위해 RMSE(Root Mean Square Error)를 사용하였다. 제안된 모델은 학습을 위해 모든 매개변수가 무작위로 초기화된 상태에서 시작하는데, 100번의 반복을 거치고 각 반복마다 32개의 영상 배치 크기가 처리된다.

모델의 검증과 최종 테스트 단계에서 RMSE와 PSNR (Peak Signal-to-Noise Ratio)을 성능 지표로 사용하였다. 검증 단계는 특히 학습 단계에서 모델의 학습 효과를 이해하는 데 도움이 된다. 테스트 단계에서는 학습 단계와 동일하게 매개변수의 연속성을 유지한다. 다양한 단계에 걸친 이러한 일관된 측정은 모델 성능을 확인하고 일반화 가능성을 예측할 수 있도록 한다.

실험 결과는 기존의 전통적인(UDCP [3], HLP [5], HDP [6], 2Steps [4], and IBLA [7]) 방법들 및 딥러닝 기반(ACT [11] and AOD [8]) 방법과 비교하였다. Fig. 3은 EUVP의 몇 가지 샘플 영상에 대한 처리 결과를 보여주는데, 전통적 방법과 딥러닝 기반 방법의 차이를 관찰할 수 있다. 전통적인 기법인 UDCP와 HLP에서는 색 균형 복원에 있어 부적절한 성능을 보여주었고, HDP와 IBLA에서는 효과적인 색상 복원을 보여 주었지만 일부 영상에서 과포화 경향이 발견되었다. 2Steps 방법은 영상이 어둡고 전체적인 성능이 저조하였다. 딥러닝 기반 방법들인 ACT와 AOD 역시 모두 화질이 충분하지 못하고 복원된 영상이 원하는 기준을 충족하지 못하였다. 이에 비해, 제안된 모델은 영상을 효율적으로 복원할 수 있었는데, 특히 균형 있는 색상 구성과 세부적인 가장자리 정보를 잘 유지하는 것을 확인할 수 있다.

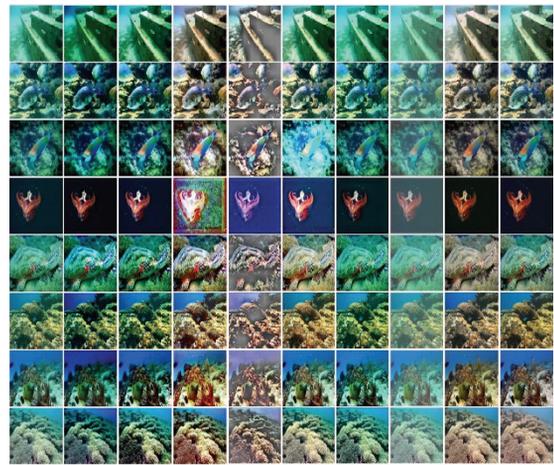


Fig. 3. Comparative analysis of restoration techniques utilizing a few test images from the EUVP Dataset: Arranged from left to right are the input image followed by the results from UDCP, HLP, HDP, 2Steps, IBLA, ACT, AOD, our proposed method and the ground truth.

복원 결과와 ground truth의 정량적인 성능 비교를 위한 RMSE와 PSNR에서도 제안된 방법이 가장 좋은 결과를 보였다. Fig. 4는 전체 테스트 영상에 대한 RMSE 평균 값을 비교하고 있다. 제안된 방법이 0.112로 가장 낮은 값을 보였는데, 이것은 영상 처리에서 오류가 가장 적다는 것을 의미한다. 특히 제안된 방법은 입력 영상과 관련 없이 매우 안정적인 RMSE를 보였다. Fig. 5는 PSNR 평균 값을 비교하고 있는데, 제안된 방법이 가장 높은 PSNR을 나타냈다. 이것은 복원 영상에서 디테일을 가장 잘 살린다는 것을 의미한다. 실험을 통해 제안된 방법이 개별 테스트와 전체 테스트 세트 모두에서 뛰어난 영상 가시성과 품질을 보여주는 것을 확인할 수 있었다.

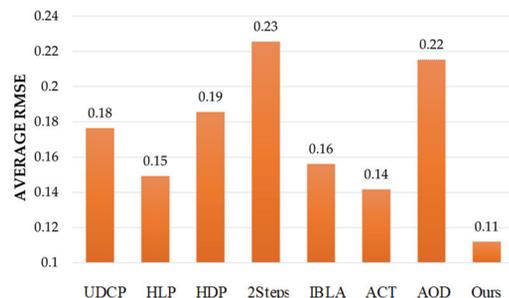


Fig. 4. Average RMSE on various state-of-the-art methods.

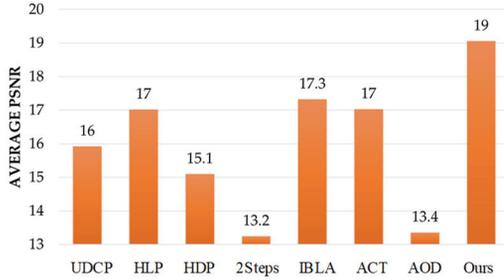


Fig. 5. Average PSNR on various state-of-the-art methods.

5. 결론

제안된 UWDCE는 수중 영상 복원에 대한 새로운 접근 방식을 제시하는데, 특히 적색과 청색 채널에 의한 색상 불균형을 해소하기 위해 화이트 밸런싱을 사용하고, 조명 향상을 위한 픽셀별 곡선 매개변수 맵을 생성하기 위해 컨볼루션 신경망을 이용하였다.

실험을 통해 제안된 방법이 영상 복원과 영상의 세부 정보 보존 측면에서 우수한 성능을 보이는 것을 확인할 수 있었는데, 균형 잡힌 색상 구성과 세부적인 가장자리 정보를 잘 유지하여 기존의 방법들에 훨씬 우수한 정성적 결과를 확인할 수 있었다. 또한 낮은 RMSE와 높은 PSNR을 나타내어 복원 영상의 오류가 적고 영상의 세부 정보가 더 잘 보존된다는 것을 확인할 수 있었다.

감사의 글

이 논문은 2023년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음.

참고문헌

1. M. J. Islam, Y. Xia and J. Sattar, "Fast Underwater Image Enhancement for Improved Visual Perception," *IEEE Robotics and Automation Letters*, vol. 5, no. 2, pp. 3227-3234, 2020.
2. He, K., Sun, J., Tang, X. Single Image Haze Removal Using Dark Channel Prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 33(12), 2341-2353.

3. P. Drews, E. Nascimento, F. Moraes, S. Botelho and M. Campos, "Transmission Estimation in Underwater Single Images," Paper presented at the Proceedings of the IEEE International Conference on Computer Vision Workshops, 2013.
4. C. O. Ancuti, C. Ancuti, C. De Vleeschouwer and P. Bekaert, "Color Balance and Fusion for Underwater Image Enhancement," *IEEE Transactions on Image Processing*, vol. 27, no. 1, pp. 379-393, 2017.
5. Berman, D., Treibitz, T., Avidan, S. Single Image Dehazing Using Haze-Lines. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 42(3), 720-734.
6. Li, C. Y., Guo, J. C., Cong, R. M., Pang, Y. W., Wang, B. Underwater Image Enhancement by Dehazing with Minimum Information Loss and Histogram Distribution Prior. *IEEE Transactions on Image Processing*, 2016, 25(12), 5664-5677.
7. Peng, Y. T., Cosman, P. C. Underwater Image Restoration Based on Image Blurriness and Light Absorption. *IEEE Transactions on Image Processing*, 2017, 26(4), 1579-1594.
8. Li, B., Peng, X., Wang, Z., Xu, J., Feng, D. Aod-Net: All-in-One Dehazing Network. Paper presented at the Proceedings of the IEEE International Conference on Computer Vision, 2017.
9. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. Generative Adversarial Nets. *Advances in Neural Information Processing Systems* 27, 2014.
10. Yang, M., Hu, K., Du, Y., Wei, Z., Sheng, Z., Hu, J. Underwater Image Enhancement Based on Conditional Generative Adversarial Network. *Signal Processing: Image Communication*, 2020, 81, 115723.
11. Yang, H. H., Fu, Y. Wavelet U-Net and the Chromatic Adaptation Transform for Single Image Dehazing. Paper presented at the 2019 IEEE International Conference on Image Processing (ICIP), 2019.
12. M. T. Mahmood and Y. K. Choi, "Mutual Structures based Improvement in Depth from Focus," *Journal of the Semiconductor & Display Technogy*, vol. 21, no. 3, pp. 17-21, 2022.

접수일: 2024년 5월 1일, 심사일: 2024년 6월 21일,
 게재확정일: 2024년 6월 21일