

Comparison of GAN Deep Learning Methods for Underwater Optical Image Enhancement

Hong-Gi Kim^{1,2}, Jung-Min Seo³ and Soo Mee Kim^{4,5}

¹Graduate Student, Department of Convergence Study on the Ocean Science and Technology, Korea Maritime and Ocean University, Busan, Korea

²OST Student-in-training, Maritime ICT R&D Center, Korea Institute of Ocean Science and Technology, Busan, Korea

³Research Specialist, Maritime ICT R&D Center, Korea Institute of Ocean Science and Technology, Busan, Korea

⁴Senior Researcher, Maritime ICT R&D Center, Korea Institute of Ocean Science and Technology, Busan, Korea

⁵Professor, Dept. of Convergence Study on the Ocean Science and Technology, Korea Maritime and Ocean University, Busan, Korea

생성적 적대 신경망 기반 수중 광학 영상 개선 기법 비교

김홍기^{1,2}, 서정민³, 김수미^{4,5}

¹한국해양대학교 해양과학기술전문대학원 대학원생

²한국해양과학기술원 해양CT융합연구센터 OST협동연구생

³한국해양과학기술원 해양CT융합연구센터 기술원

⁴한국해양과학기술원 해양CT융합연구센터 선임연구원

⁵한국해양대학교 해양과학기술전문대학원 겸직부교수

KEY WORDS: Generative adversarial networks 생성적 적대 신경망, Image fusion 영상융합, Image enhancement 영상품질 개선, Underwater optical image 수중 광학 영상, Underwater image deep learning techniques 수중영상 딥러닝 기법

ABSTRACT: Underwater optical images face various limitations that degrade the image quality compared with optical images taken in our atmosphere. Attenuation according to the wavelength of light and reflection by very small floating objects cause low contrast, blurry clarity, and color degradation in underwater images. We constructed an image data of the Korean sea and enhanced it by learning the characteristics of underwater images using the deep learning techniques of CycleGAN (cycle-consistent adversarial network), UGAN (underwater GAN), FUnIE-GAN (fast underwater image enhancement GAN). In addition, the underwater optical image was enhanced using the image processing technique of Image Fusion. For a quantitative performance comparison, UIQM (underwater image quality measure), which evaluates the performance of the enhancement in terms of colorfulness, sharpness, and contrast, and UCIQE (underwater color image quality evaluation), which evaluates the performance in terms of chroma, luminance, and saturation were calculated. For 100 underwater images taken in Korean seas, the average UIQMs of CycleGAN, UGAN, and FUnIE-GAN were 3.91, 3.42, and 2.66, respectively, and the average UCIQEs were measured to be 29.9, 26.77, and 22.88, respectively. The average UIQM and UCIQE of Image Fusion were 3.63 and 23.59, respectively. CycleGAN and UGAN qualitatively and quantitatively improved the image quality in various underwater environments, and FUnIE-GAN had performance differences depending on the underwater environment. Image Fusion showed good performance in terms of color correction and sharpness enhancement. It is expected that this method can be used for monitoring underwater works and the autonomous operation of unmanned vehicles by improving the visibility of underwater situations more accurately.

1. 서 론

최근 극한적이고 다변하는 수중환경에서 사람을 대신하여 안전하고 정확하게 수중작업을 수행하기 위하여 무인자동기술을 적극적

Received 6 December 2021, revised 21 December 2021, accepted 30 December 2021

Corresponding author Soo Mee Kim: +82-51-664-3041, smekim@kiost.ac.kr

© 2022, The Korean Society of Ocean Engineers

This is an open access article distributed under the terms of the creative commons attribution non-commercial license (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.




Fig. 1 Light attenuation by water and floating particles causes low visibility with haziness and color cast in underwater optical images




Fig. 2 GAN model consisting of a generator (G) and a discriminator (D).

으로 적용하고 있으며 무인자동기술에서 수중 상황을 가시화하는 영상 센싱 기술은 필수적인 요소기술이다(Schettini and Corchs, 2010; Bharal, 2015). Fig. 1에 나타난 바와 같이 수중 영상 센서 중 수중 광학카메라로 촬영한 영상은 물과 플랑크톤, 모래 등과 같은 부유물에 의한 빛의 흡수와 산란 현상으로 인하여 낮은 대조도, 흐릿한 선명도를 초래하며, 물의 탁도 및 촬영 카메라의 특성에 따라 영상 품질의 저하 정도가 다르다. 또한, 대기 환경과 다르게 빛의 붉은색 파장은 파란색이나 초록색보다 길어서 물을 잘 통과하지 못한다. 그러므로 수중에서 촬영한 광학영상은 붉은색보다 파란색이나 초록색이 보다 강조되는 경향을 보인다(Mobley and Mobley, 1994).

수중영상의 색조, 대조도 및 선명도를 개선하기 위한 다양한 알고리즘이 고안되었다. 빛의 파장에 따라 다르게 색조가 저하되는 물리적인 현상을 이용한 DCP(Dark channel prior) 기법, 일반적인 영상 처리 알고리즘을 여러 단계로 적용하거나 수중 광학영상화 과정에 대한 수학적 모델 기반의 알고리즘이 제안되었다(He et al., 2010; Li et al., 2012; Ancuti et al., 2017). 또한, 최근 컴퓨터 비전 분야에서 성공적인 적용 사례를 선보이는 딥러닝 기법이 수중영상의 품질을 개선하기 위하여 활용되고 있다(Fabbri et al., 2018; Han et al., 2018; Uplavikar et al., 2019; Chen et al., 2019 Islam et al., 2020; Li and Cavallaro, 2020; Wang et al., 2020; Zhang et al., 2021). 딥러닝 기법의 성능은 학습데이터를 어떻게 구성하는지가 중요한 바, 수중영상의 품질을 개선하기 위하여 수중영상과 깨끗한 영상 데이터쌍이 필요하다. 하지만 수중 환경과 동일한 장면의 깨끗한 영상을 얻는 것은 매우 어렵다. 수중영상과 깨끗한 영상 데이터쌍을 구성하기 위하여 미리 비지도 학습된 CycleGAN(Cycle-Consistent generative adversarial networks)이 활용되었다(Fabbri et al., 2018). 한국 해역에서 촬영한 수중영상을 포함하여 학습데이터를 구성할 경우, GAN 기법이 다른 영상품질 개선 기법보다 색조 보정에 좋은 성능을 보이는 것이 보고되었다(Kim and Kim, 2020).

본 연구에서는 수중 ImageNet 데이터베이스와 한국 해역에서 촬영한 수중 영상으로 학습데이터를 구성하였다(Deng et al., 2009). 딥러닝 기법으로 CycleGAN, UGAN(Underwater GAN) 및 FUnIE-GAN(Fast underwater image enhancement GAN)을 훈련하였다. 영상 개선도 평가를 위하여 수중 영상의 채도, 선명도, 대조도를 정량적으로 평가하는 UIQM(Underwater image quality measure)과 채도, 휘도, 색의 포화도를 측정하는 UCIQE(Underwater color image quality evaluation)를 이용하여 세 GAN 기법과 영상 융합(Image fusion) 기반 수중영상 개선 기법을 비교하였다.

2. GAN 기반 수중 광학영상 개선 기법

GAN(Generative adversarial network)은 생성기(Generator, G)와 판별기(Discriminator, D)의 두 네트워크로 구성되며(Fig. 2), 생성기는 판별기를 잘 속이는 가짜 영상을 생성하기 위하여, 판별기는 생성기가 만든 가짜 영상의 진위를 판별하기 위하여 서로 경쟁적으로 학습한다(Goodfellow et al., 2014). GAN을 학습하기 위하여 식 (1)과 같이 목적 함수(Objective function) $L_{GAN}(G, D)$ 에 대해 최적화 문제를 푼다.

$$\min_G \max_D L_{GAN}(G, D) = \log D + \log\{1 - D(G(z))\} \tag{1}$$

식 (1)에서 z 는 무작위 입력 잡음이며, G 와 D 는 각각 생성기와 판별기 함수이다. 식 (1)을 기반으로 $G(z)$ 는 가짜 영상을 생성해 D 함수를 속여 목적 함수 값이 최소가 되게 훈련시키며, D 함수는 G 가 생성한 가짜 영상에 속지 않고 목적 함수 값이 최대가 되게 훈련된다. 본 연구에서는 딥러닝 기반 수중 광학영상 개선 기법으로 CycleGAN, UGAN 및 FUnIE-GAN을 고려하였다.

2.1 수중 광학영상 개선용 GAN 모델

CycleGAN은 데이터 도메인 X 와 Y 의 상호 매핑할 수 있는 모델($G_{X \rightarrow Y}, G_{Y \rightarrow X}$)을 학습하기 위하여 고안되었다. CycleGAN은 두 데이터 도메인의 생성기와 판별기 쌍으로 구성되어 각 생성기와 판별기 네트워크는 각각 Fig. 3(a)와 (b)의 Resnet-9block(He et al., 2016)과 70×70 patch 크기의 PatchGAN으로 구성되었다(Zhu et al., 2017).

생성기인 Resnet-9block 네트워크는 Residual block을 9번 반복 사용한다. 기존의 출력값인 $F(x)$ 의 값에 초기의 입력값 x 를 더하여 추가정보를 학습시켜 성능을 높여주는 네트워크이다. 판별기인 PatchGAN은 총 5개의 컨볼루션 층으로 이루어져 있다. 선행되는 4개의 컨볼루션은 stride 2로 진행되었으며 마지막 컨볼루션은 stride 1로 연산하며 70×70 patch를 이용해 최종적으로 16×16 의 특징맵을 얻어낸다. 식 (2)에서 CycleGAN의 목적 함수, $L_{CycleGAN}(G, D)$ 는 식 (1)의 GAN adversarial 목적 함수와 식 (3)의 cycle consistency 손실 함수로 정의한다. 식 (2)에서 x 와 y 는 각각 X 와 Y 도메인의 데이터를 나타낸다. $G_{X \rightarrow Y}$ 와 $G_{Y \rightarrow X}$ 는 각각 $X \rightarrow Y$ 와 $Y \rightarrow X$ 로 데이터 도메인 간 변환되는 생성기이다. D_X 와 D_Y 는 각 데이터 도메인에서 생성되는 가짜 영상의 진위를 구별하는 판별기이다.

$$L_{CycleGAN}(G_{X \rightarrow Y}, G_{Y \rightarrow X}, D_X, D_Y) = L_{GAN}(G_{X \rightarrow Y}, D_Y, X, Y) + L_{GAN}(G_{Y \rightarrow X}, D_X, Y, X) + \lambda L_{cyc}(G_{X \rightarrow Y}, G_{Y \rightarrow X}) \quad (2)$$

$$L_{cyc}(G_{X \rightarrow Y}, G_{Y \rightarrow X}) = [\|G_{Y \rightarrow X}(G_{X \rightarrow Y}(x)) - x\|] + [\|G_{X \rightarrow Y}(G_{Y \rightarrow X}(y)) - y\|] \quad (3)$$

Cycle consistency 손실 함수는 생성기가 만든 영상과 원본 영상의 차이를 추가하여 입력된 수중영상의 특성을 유지하면서 깨끗한 영상의 특징을 최적으로 학습하게 한다. 배치 크기는 6, 학습률(Learning rate)은 0.0002, 반복 횟수(Epoch)는 60으로 설정하여 CycleGAN을 훈련하였다.

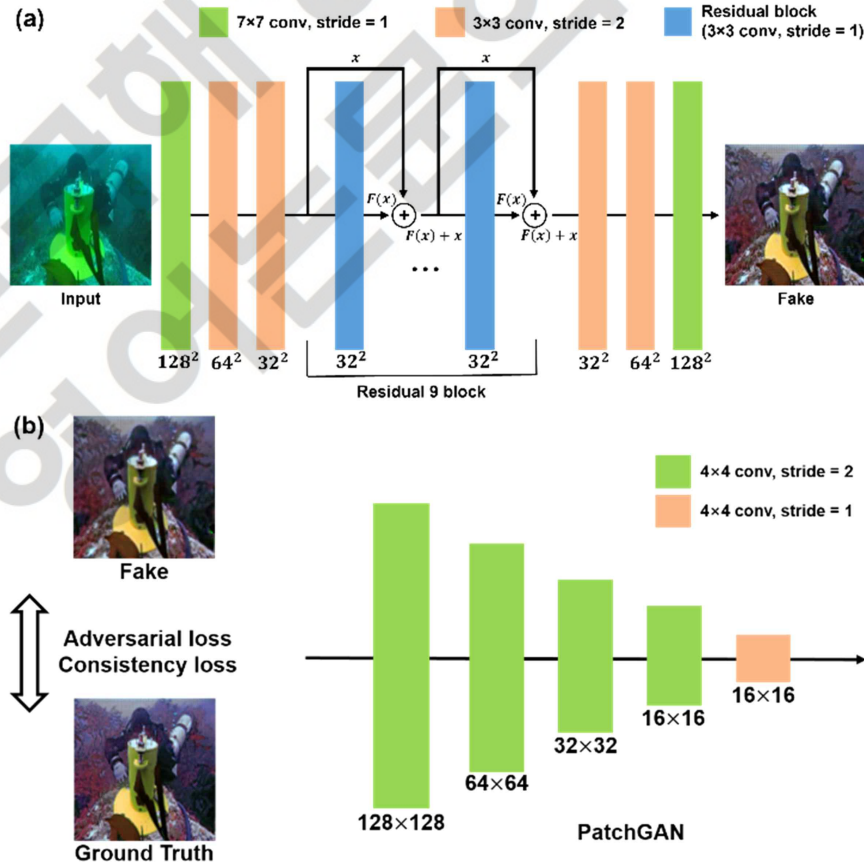


Fig. 3 Network architectures of CycleGAN: (a) generator based on Resnet-9 block and (b) discriminator based on PatchGAN.

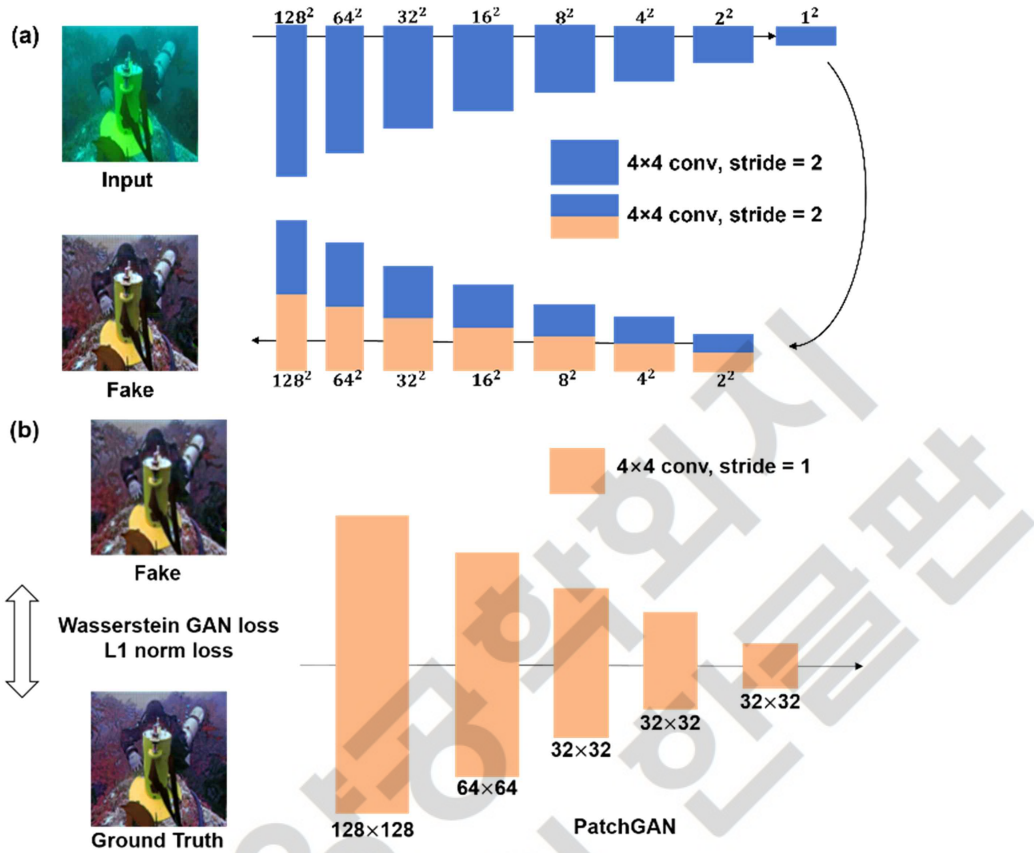


Fig. 4 Network architecture of UGAN: (a) generator based on U-Net and (b) discriminator based on PatchGAN.

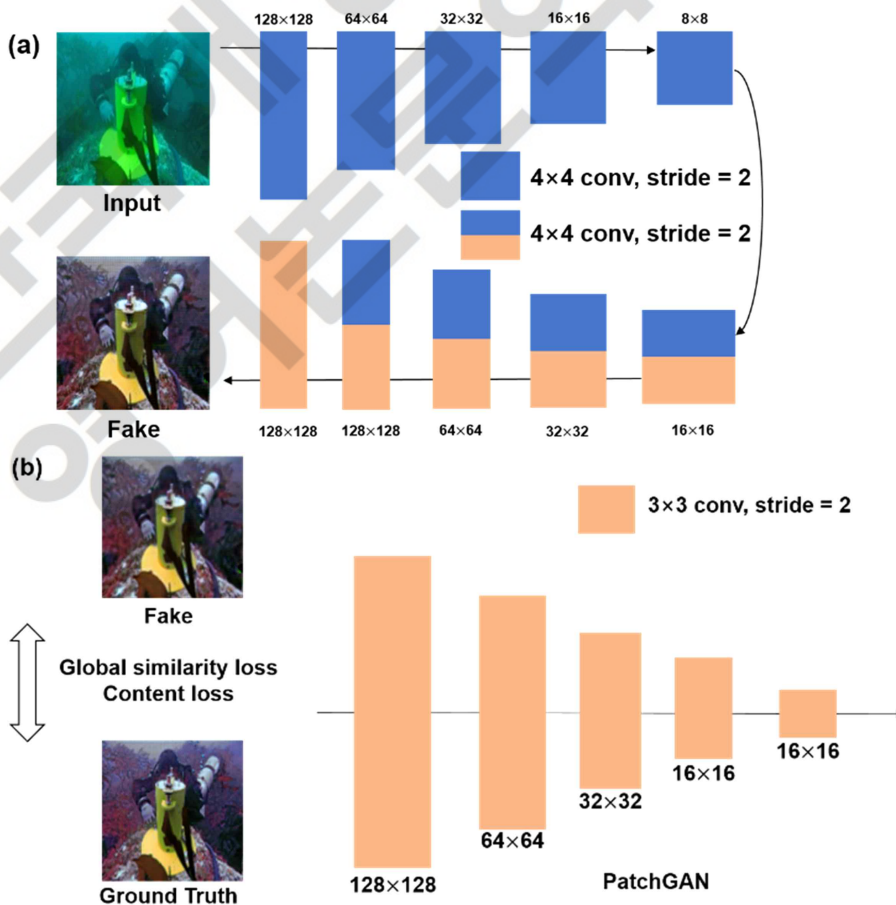


Fig. 5 Network architecture of FUnIE-GAN: (a) generator based on U-Net and (b) discriminator based on PatchGAN

UGAN의 생성기와 판별기 네트워크는 Fig. 4와 같이 각각 U-Net와 PatchGAN으로 구성되었다(Ronneberger et al., 2015; Fabbri et al., 2018). U-Net은 8개의 인코더 컨볼루션 층과 7개의 디코더 컨볼루션 층으로 구성되었다. PatchGAN은 5개의 컨볼루션 층으로 구성되어 7070 patch를 이용해 최종적으로 3232의 특징맵을 얻어내어 판별한다. 식 (4)의 UGAN 목적 함수, L_{UGAN} 은 식 (5)의 Wasserstein GAN 목적 함수(Arjovsky et al., 2017)와 식 (6)의 L1-norm 손실함수로 정의한다. 식 (5)와 (6)의 I^{GT} 와 I^{UW} 는 각각 왜곡이 개선된 Ground truth의 영상과 왜곡이 존재하는 영상을 뜻한다. 식 (5)에서는 식 (1)과 같이 왜곡된 영상과 Ground truth를 이용하여 생성기와 판별기를 적대적으로 학습한다. Gradient penalty, λ_{GP} 를 추가로 적용하여 민감하게 변동하는 gradient를 안정적으로 학습되게 해준다. 식 (6)에서는 왜곡이 존재하지 않는 영상과 왜곡이 존재하는 영상의 차이 정도를 손실 함수로 이용한다. 배치 크기는 32, 학습률은 0.0001, 반복 횟수는 100으로 UGAN을 학습하였다.

$$L_{UGAN} = \min_G \max_D L_{WGAN}(G, D) + \lambda_1 L_{L1}(G) \quad (4)$$

$$L_{WGAN}(G, D) = D(I^{GT}) - D(G(I^{UW})) + \lambda_{GP} \quad (5)$$

$$L_{L1} = E[\|I^{GT} - G(I^{UW})\|] \quad (6)$$

Fig. 5과 같이 FUnIE-GAN의 생성기는 5개 컨볼루션 층의 인코더와 5개 컨볼루션 층의 디코더로 구성된 U-Net 구조를 가진다. 판별기는 5개 컨볼루션 층으로 이루어져 7070 patch를 이용해 1616의 결과 특징맵을 제공하는 PatchGAN이다(Islam et al., 2020). 배치 크기는 4, 학습률은 0.0003, 반복 횟수는 100으로 FUnIE-GAN을 학습하였다. 식 (7)의 FUnIE-GAN의 목적 함수, $L_{FUnIE-GAN}$ 는 식 (1)의 Adversarial 목적 함수와 흐릿한 특성을 줄여주는 전역 유사도(Global similarity) loss (8)와 생성기가 Ground truth의 특징을 높은 수준으로 추출할 수 있게 해주는 Content loss (9)를 목적 함수에 포함한다.

$$L_{FUnIE-GAN} = \min_G \max_D L_{GAN}(G, D) + \lambda_1 L_{L1}(G) + \lambda_c L_{con}(G) \quad (7)$$

$$L_1(G) = E_{UW, GT, Z} [\|GT - G(UW, Z)\|] \quad (8)$$

$$L_{con}(G) = E_{UW, GT, Z} [\|\Phi(GT) - \Phi(G(UW, Z))\|] \quad (9)$$

식 (8)과 (9)의 UW , GT , Z 는 각각 왜곡된 영상, Ground truth 영상, 무작위 잡음이다. 식 (8)에서는 생성기 G 로부터 생성된 영상과 Ground truth 영상의 선명함 차이 정도를 이용해 뿌옇게 나오는 부분을 개선해준다. 식 (9)에서는 VGG-19 네트워크로 미리 학습되어 영상의 특징을 추출해주는 Φ 함수를 이용한다.

Ground truth 영상과 생성기로부터 나온 영상을 함수를 이용해 특징을 추출하여 타겟 이미지의 최대한 비슷한 이미지를 만들 수 있게 해주는 Loss값을 제공해준다.

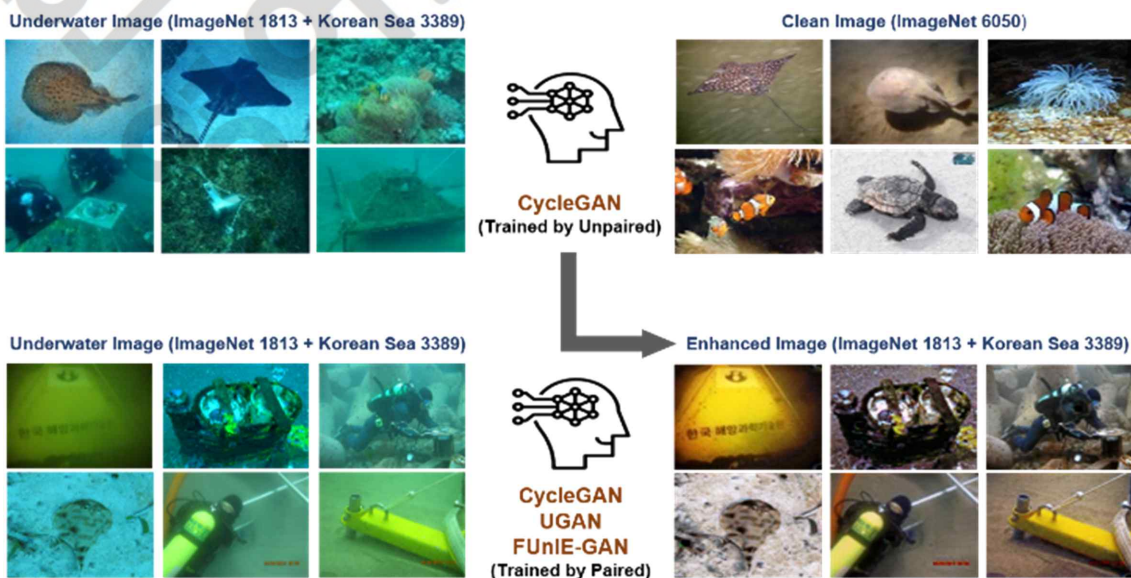


Fig. 6 Unpaired and paired training datasets

2.2. 학습 데이터 셋

GAN 기반 수중 영상 개선 기법을 학습하기 위하여 수중 영상과 깨끗한 영상으로 두 가지 학습 데이터셋을 구성하였다. 첫 번째 학습 데이터셋(Unpaired) 중 수중 영상은 총 5202장이며 ImageNet 데이터베이스의 1813장과 한국 해역(거제, 동해, 제주 등)에서 직접 촬영한 3389장의 수중 영상으로 구성하였고, ImageNet 데이터베이스에서 6050장의 깨끗한 영상을 선정하였다(Deng et al., 2009).

먼저 Unpaired 데이터셋으로 CycleGAN을 학습하여 수중 영상과 동일한 장면의 깨끗한 영상을 생성하여 총 5202장의 두 번째 데이터셋(Paired)을 구성하였다(Fig. 6). 본 논문에서 비교하는 CycleGAN, UGAN 및 FUnIE-GAN은 Paired 데이터셋으로 훈련되었다. Python 버전 3.6, Tensorflow 버전 2.4.1, Keras 버전 2.1.6과, 두 개의 NVIDIA GeForce RTX 2080 Ti GPU를 사용하여 훈련을 진행하였다.

3. 영상 융합 기반 수중 광학영상 개선 기법

영상 융합 기법은 Fig. 7과 같이 색조 보정을 위한 백색균형(White balancing) 단계, 경계 및 대조도 강화 단계와 강화된 두 영상의 융합 단계로 구성된다(Ancuti et al., 2017). 초록 빛의 에너지는 붉은 빛과 파란 빛의 에너지보다 높기 때문에 수중에서 상대적으로 더 투과되어 카메라에 잘 도달한다. 영상 융합 기법의 백색균형 단계는 붉은 빛과 파란 빛의 신호 감쇠에 대해 보상하기 위하여 신호 전달이 잘 되는 초록 빛을 이용한다. 식 (10)과 (11)는 백색균형 영상 내 각 픽셀의 붉은 빛 WB_r 과 파란 빛 WB_b 을 보상해준다. 각 색조의 평균 값 (I_r, I_g, I_b), 한 픽셀의 각 색조 값 (I_r, I_g, I_b) 및 가중치 α 와 β 를 이용하여 보상된다.

$$WB_r = I_r(x) + \alpha(I_g - I_r)(1 - I_r(x))(I_g(x)) \quad (10)$$

$$WB_b = I_b(x) + \beta(I_g - I_b)(1 - I_b(x))(I_g(x)) \quad (11)$$

다른 수중 환경에서 촬영된 영상은 다른 색조 편향을 보이므로 식 (10)과 (11)의 가중치 α 와 β 를 영상에 따라 다르게 설정할 필요가 있다. α 와 β 를 결정하기 위하여 화이트 밸런스 후 붉은 빛과 파란 빛의 값을 감쇠가 상대적으로 적게 일어난 초록 빛의 평균 값으로 대체하여 식 (12)과 (13)와 같이 가중치 값을 유도하였다.

$$\alpha = 1 / (1 - (I_r(x) * I_g(x))) \quad (12)$$

$$\beta = 1 / (1 - (I_b(x) * I_g(x))) \quad (13)$$

$$UMP\{WB\} = WB + \gamma(WB - (Gauss * WB)) \quad (14)$$

$$J = \omega_1 UMP\{WB\} + \omega_2 CLAHE\{WB\} \quad (15)$$

두번째 영상 강화 단계에서는 경계 신호와 대조도를 각각 강화한다. 경계 강화를 위한 Unsharp masking principle 기법 (14)은 가우시안 필터를 적용하여 원본 영상과의 경계선 차이 정보를 추출하여 강화한다. WB 는 백색 균형 단계에서 색조편향이 보정된 영상이며 γ 과 $Gauss$ 는 각각 경계선 차이 정보를 적용하는 정도인 가중치와 가우시안 필터 함수이다. 대조도 강화를 위하여 CLAHE(Contrast limit adaptive histogram equalization) 방법을 이용하였다. 영상을 일정한 크기의 블록으로 나눈 후 각 블록의 히스토그램의 평활화를 진행하여 대조도가 강화된 영상을 얻는다.

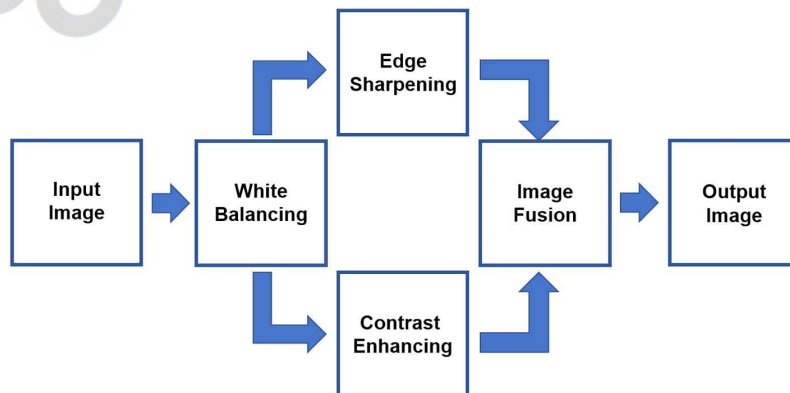


Fig. 7 Three image processing steps of image fusion enhancement method

식 (15)의 세번째 영상 융합 단계는 두번째 단계의 경계선 강화 결과 영상과 대조도 강화 결과 영상을 가중치를 이용하여 융합하여 최종 개선 결과 영상 (J)을 얻는다. 식 (15)에서 가중치는 휘도 채널에 Laplacian 필터를 적용한 값인 ω_1 과 색조 채널과 휘도 채널의 차이 값인 ω_2 를 이용한다.

4. 결 과

Fig. 8은 실해역에서 촬영한 수중영상과 학습된 GAN 기법들과 영상 융합의 결과를 정성적으로 나타낸다. CycleGAN과 UGAN은 모든 수중환경에 있어 전체적으로 영상품질이 상당히 향상된 결과를 보였지만 경우에 따라 인공물, 잡음 등이 생성되는 것을(Fig. 8(c)의 물고기 몸통 부위) 확인할 수 있었다. 또한, FUNIE-GAN의 경우 수중환경에 따라 개선되는 편차가 큰 성능을 보였다. 영상 융합의 경우 색조 보정에 있어서 향상된 결과 값을 보이지만 빛에 반사되는 부분의 잡음은 처리하지 못하는 것을 확인할 수 있었다.

본 연구에서 고려한 수중 광학영상 개선기법을 정량적으로 비교하기 위하여 UIQM과 UCIQE를 측정하였다. UIQM은 채도(Colorfulness), 선명도(Sharpness) 및 대조도(Contrast)의 가중치 합으로 수중영상의 품질을 평가하는 지표이며 식 (16)과 같이 표현된다(Panetta et al., 2015). UIQM을 고안한 본래 참고문헌에서 다양한 수중 환경 및 영상장비에서 얻은 30개 영상의 채도, 선명도 및 대조도로 부터 추정한 세 가중치 $a_1=0.0282$, $a_2=0.2983$ 및 $a_3=0.0339$ 로 설정하였다.

$$UIQM = a_1 UICM + a_2 UISM + a_3 UICnM \quad (16)$$

UCIQE는 채도(Chroma), 휘도(Luminance)와 색의 포화도(Saturation)의 가중치 합으로 계산되는 지표이다(Yang and Sowmya 2015). 식 (17)와 같이 표현되며, UCIQE를 고안한 본래 참고문헌에서 수중영상의 채도, 휘도, 색의 포화도에서 추정된 가중치 $b_1=0.4680$, $b_2=0.2745$, $b_3=0.2576$ 로 설정하였다.

$$UCIQE = b_1 \sigma_{chr} + b_2 \sigma_{lum} + b_3 \mu_{sat} \quad (17)$$

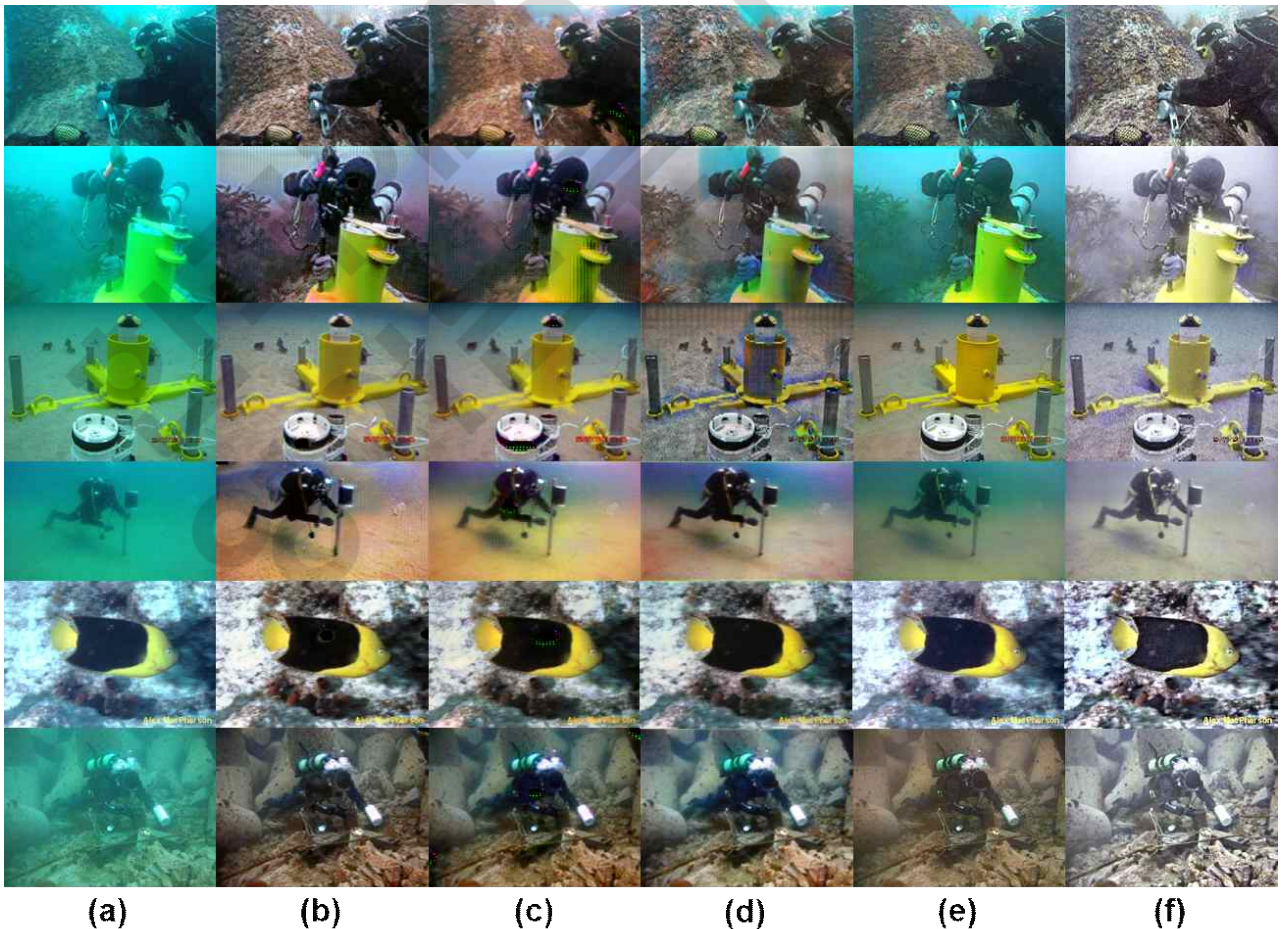


Fig. 8 (a) Original and enhanced underwater images by (b) CycleGAN-Unpaired, (c) CycleGAN-Paired, (d) UGAN, (e) FUNIE-GAN, (f) Image fusion

Table 1 Comparison of UIQM and UCIQE computed from 100 underwater images and the enhanced images by GANs and Image fusion (SD: Standard deviation)

Method	UIQM (mean±SD)	UCIQE (mean±SD)
Original	1.808±1.286	20.202±5.955
CycleGAN-UnPaired	3.912±0.508	29.683±2.552
CycleGAN-Paired	2.969±1.003	29.899±2.138
UGAN	3.422±0.831	26.768±3.231
FUnIE-GAN	2.658±1.164	22.883±5.711
Image fusion	3.628±0.954	23.592±4.907

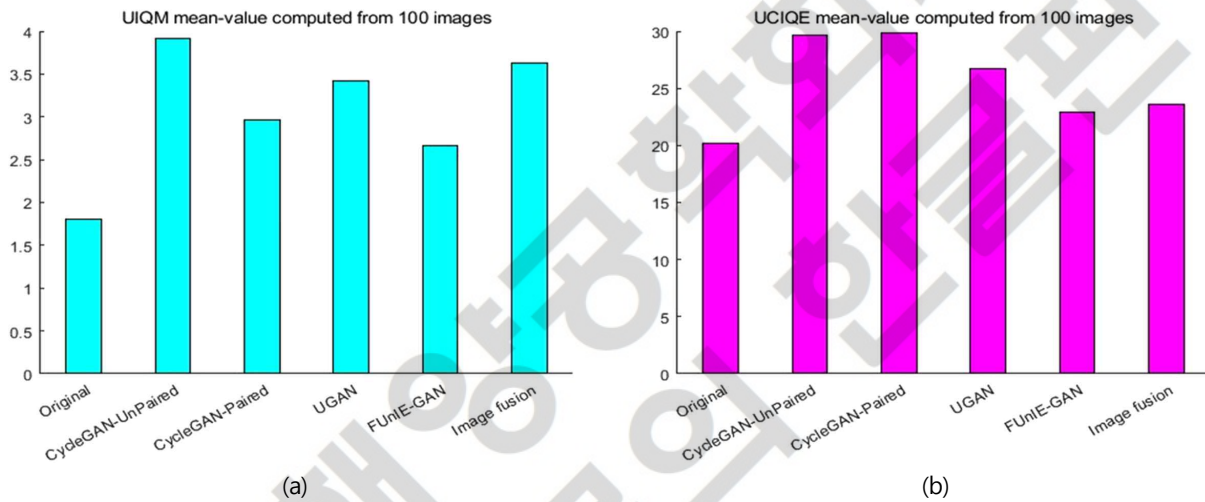


Fig. 9 Comparative graphs of (a) mean UIQM and (b) mean UCIQE computed from 100 underwater images.

Table 2 Comparison of time for enhancing 100 underwater images by GANs and Image fusion.

Method	Enhancement time per image
CycleGAN-UnPaired	0.21 s
CycleGAN-Paired	0.23 s
UGAN	0.04 s
FUnIE-GAN	0.15 s
Image fusion	0.05 s

Table 1과 Fig. 9는 100장의 실험용 수중영상과 GAN기법 및 영상융합기법으로 향상된 영상의 UIQM과 UCIQE의 평균값과 편차를 정량적으로 비교하였다. 모든 수중 광학영상 개선기법은 실험용 수중영상보다 향상된 UIQM과 UCIQE를 보였다. GAN 기법 중 CycleGAN-UnPaired가 가장 좋은 평균 UIQM과 UCIQE를 보였다. Paired 데이터셋을 사용한 UGAN과 영상융합 기법은 유사한 성능을 보였다. FUnIE-GAN의 경우 UIQM과 UCIQE의 가장 큰 편차를 보였다.

Table 2는 수중 광학영상 개선 방법의 평균 연산 시간을 비교하였다. 동일한 조건에서 비교하기 위하여 앞서 사용한 총 100장의 수중영상 크기를 256×256으로 재조정하였다. GAN 기법 중 UGAN이 가장 빠른 연산속도를 보였으며 영상융합 기법과 유사한 속도를 보였다.

5. 결 론

본 논문에서 수중영상의 품질을 개선하기 위하여 CycleGAN, UGAN 및 FUnIE-GAN 딥러닝 기법과 영상 융합 방법을 이용하여 100장의 실험용 수중 영상에 적용하고 UIQM과 UCIQE 기준으로 품질 향상도를 비교 평가하였다. CycleGAN과 UGAN은 다양한 수중환경에

서 정성적, 정량적으로 우수한 성능을 보였지만 경우에 따라 인공물이 생성되었다. FUnIE-GAN은 수중환경에 따라 성능 편차가 매우 컸으며, 영상 융합은 색조 보정과 선명도 개선에서 좋은 성능을 보였다. 수중영상의 개선을 통해 수중상황을 보다 정확하게 가시화하여 수중작업 모니터링 및 무인이동체 자율운항경로 계획에 활용 가능할 것으로 기대된다.

Conflict of Interest

No potential conflict of interest relevant to this article was reported.

Funding

2021년 과학기술정보통신부 재원으로 한국연구재단(수중 스테레오 카메라 입체가시화 기술 개발, NRF-2021R1A2C2006682)과 2021년 해양수산부 재원으로 해양수산과학기술진흥원(해양장비 실패역 성능 검증을 위한 시험평가 선박 및 시스템 구축)의 지원을 받아 수행된 연구임.

References

- Ancuti, C.O., Ancuti, C., De Vleeschouwer, C., & Bekaert, P. (2017). Color Balance and Fusion for Underwater Image Enhancement. *IEEE Transactions on Image Processing*, 27(1), 379–393. <https://doi.org/10.1109/TIP.2017.2759252>
- Arjovsky, M., Chintala, S., & Bottou, L. (2017). Wasserstein Generative Adversarial Networks. *Proceedings of the 34th International Conference on Machine Learning*, PMLR, 70, 214–223.
- Bharal, S. (2015). Review of Underwater Image Enhancement Techniques. *International Research Journal of Engineering and Technology*, 2(3), 340–344.
- Chen, X., Yu, J., Kong, S., Wu, Z., Fang, X., & Wen, L. (2019). Towards Real-Time Advancement of Underwater Visual Quality with GAN. In *IEEE Transactions on Industrial Electronics*, 66(12), 9350–9359. <https://doi.org/10.1109/TIE.2019.2893840>
- Deng, J., Dong, W., Socher, R., Li, L.J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A Large-Scale Hierarchical Image Database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>
- Fabbri, C., Islam, M.J., & Sattar, J. (2018, May). Enhancing Underwater Imagery Using Generative Adversarial Networks. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, 7159–7165. <https://doi.org/10.1109/ICRA.2018.8460552>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., WardNe-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, 27.
- Han, M., Lyu, Z., Qiu, T., & Xu, M. (2018). A Review on Intelligence Dehazing and Color Restoration for Underwater Images. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 50(5), 1820–1832. <https://doi.org/10.1109/TSMC.2017.2788902>
- He, K., Sun, J., & Tang, X. (2010). Single Image Haze Removal Using Dark Channel Prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(12), 2341–2353. <https://doi.org/10.1109/TPAMI.2010.168>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Islam, M.J., Xia, Y., & Sattar, J. (2020). Fast Underwater Image Enhancement for Improved Visual Perception. *IEEE Robotics and Automation Letters*, 5(2), 3227–3234. <https://doi.org/10.1109/LRA.2020.2974710>
- Kim, D.G., & Kim, S.M. (2020). Single Image-based Enhancement Techniques for Underwater Optical Imaging. *Journal of Ocean Engineering and Technology*, 34(6), 442–453. <https://doi.org/10.26748/KSOE.2020.030>
- Li, C.Y., & Cavallaro, A. (2020, October). Cast-Gan: Learning to Remove Colour Cast From Underwater Images. In *2020 IEEE International Conference on Image Processing (ICIP)*, 1083–1087. <https://doi.org/10.1109/ICIP40778.2020.9191157>
- Li, W.J., Gu, B., Huang, J.T., Wang, S.Y., & Wang, M.H. (2012). Single Image Visibility Enhancement in Gradient Domain. *IET Image Processing*, 6(5), 589–595.
- Mobley, C.D., & Mobley, C.D. (1994). *Light and Water: Radiative Transfer in Natural Waters*. Academic Press.
- Panetta, K., Gao, C., & Agaian, S. (2015). Human-Visual-System- Inspired Underwater Image Quality Measures. *IEEE Journal of Oceanic Engineering*, 41(3), 541–551. <https://doi.org/10.1109/JOE.2015.2469915>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, Cham, 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
- Schettini, R., & Corchs, S. (2010). Underwater Image Processing: State of the Art of Restoration and Image Enhancement Methods. *EURASIP*

Journal on Advances in Signal Processing, 2010, 1-14. <https://doi.org/10.1155/2010/746052>

Uplavikar, P. M., Wu, Z., & Wang, Z. (2019, May). All-in-One Underwater Image Enhancement Using Domain-Adversarial Learning. In CVPR Workshops, 1-8.

Wang, J., Li, P., Deng, J., Du, Y., Zhuang, J., Liang, P., & Liu, P. (2020). CA-GAN: Class-Condition Attention GAN for A Underwater Image Enhancement. IEEE Access, 8, 130719-130728. <https://doi.org/10.1109/ACCESS.2020.3003351>

Yang, M., & Sowmya, A. (2015). An Underwater Color Image Quality Evaluation Metric. IEEE Transactions on Image Processing, 24(12), 6062-6071. <https://doi.org/10.1109/TIP.2015.2491020>.

Zhang, T., Li, Y., & Takahashi, S. (2021). Underwater Image Enhancement Using Improved Generative Adversarial Network. Concurrency and Computation: Practice and Experience, 33(22), e5841. <https://doi.org/10.1002/cpe.5841>

Zhu, J.Y., Park, T., Isola, P., & Efros, A.A. (2017). Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. In Proceedings of the IEEE International Conference on Computer Vision, 2223-2232.

Author ORCIDs

Author name	ORCID
Kim, Hong-Gi	0000-0001-7731-8429
Seo, Jung-Min	0000-0001-6323-7783
Kim, Soo Mee	0000-0001-8414-1297