

PENINGKATAN KUALITAS CITRA BAWAH AIR MENGGUNAKAN GAN DENGAN MEKANISME *RESIDUAL* DAN *ATTENTION*

Nursanti Abdurrachman^{*1}, Dina Chahyati²

^{1,2}Universitas Indonesia, Depok

Email: ¹nursanti.abdurrachman@gmail.com, ²dina@cs.ui.ac.id

*Penulis Korespondensi

(Naskah masuk: 24 September 2024, diterima untuk diterbitkan: 09 Desember 2025)

Abstrak

Citra bawah air sering mengalami penurunan kualitas yang disebabkan oleh proses redaman dan hamburan cahaya yang dipengaruhi oleh panjang gelombang serta jarak antara objek dan kamera. Faktor-faktor seperti gangguan pencahayaan dan kompleksitas latar bawah air sering kali menyebabkan citra menjadi buram, mengalami perubahan warna, dan mengalami berbagai bentuk degradasi visual lainnya. Upaya peningkatan kualitas citra bawah air tidak hanya bertujuan untuk memperbaiki tampilan visual, tetapi juga untuk menghasilkan citra yang lebih baik sebagai masukan bagi proses pengolahan citra lanjutan. Keunikan dan kompleksitas dari citra bawah air membuat metode peningkatan konvensional yang dirancang untuk kondisi seperti cahaya rendah dan berkabut menjadi kurang efektif bila diterapkan dalam konteks bawah air. Untuk mengatasi hal ini, penelitian ini memanfaatkan Generative Adversarial Networks (GANs) yang dilengkapi dengan mekanisme *attention* dan *residual* pada bagian generator. Penggunaan *attention* dan *residual mechanism* memungkinkan jaringan untuk fokus pada bagian penting dari gambar dan membantu dalam pemulihannya yang hilang selama proses peningkatan gambar. Penelitian ini menggunakan dataset EUVP dengan data latih sebanyak 3330 citra, data uji sebanyak 1110 citra, dan data validasi sebanyak 1110 citra. Pendekatan yang diusulkan pada penelitian ini mampu menjawab tantangan-tantangan utama dalam peningkatan citra bawah air. Citra yang dihasilkan memiliki keseimbangan yang cukup baik antara kualitas alami gambar dan kesamaan struktural dengan gambar target. Pendekatan yang diusulkan dalam penelitian ini juga mampu menyeimbangkan pemulihannya warna dan preservasi tekstur sehingga menghasilkan gambar yang lebih alami dan realistik, tanpa artefak warna yang berlebihan atau kehilangan detail tekstur. Hasil evaluasi menunjukkan metode yang diusulkan mencapai nilai PSNR 23.7966, SSIM 0.7219, UIQM 1.4485, dan UCIQE 0.2389.

Kata kunci: *peningkatan citra bawah air, GANs, attention mechanism, residual mechanism*

IMPROVING THE QUALITY OF UNDERWATER IMAGES USING GAN WITH RESIDUAL AND ATTENTION MECHANISM

Abstract

Underwater images inevitably suffer from quality degradation issues caused by wavelength- and distance-dependent attenuation and scattering. Light interference and complex underwater backgrounds frequently cause blurriness, color distortion, and other degradation problems in underwater images. Enhancing underwater image quality not only aims to improve visual perception but also to provide higher-quality inputs for other image processing techniques. The uniqueness and complexity of underwater images make enhancement methods designed to address issues like low light and foggy conditions unsuitable for underwater image enhancement tasks. Attention and residual mechanisms allow the network to focus on important parts of the image and aid in recovering lost information during the enhancement process. This research employs Generative Adversarial Networks (GANs) for underwater image enhancement, incorporating attention and residual mechanisms into the generator part. This study uses the EUVP dataset with 3330 training images, 1110 test images, and 1110 validation images. This research's proposed method can address the challenges faced by underwater images. The resulting images achieve a good balance between natural image quality and structural similarity with the ground truth. The proposed method in this study is also able to balance color recovery and texture preservation, producing more natural and realistic images without excessive color artifacts or loss of texture details. Evaluation results show that the proposed method achieves PSNR 23.7966, SSIM 0.7219, UIQM 1.4485, and UCIQE 0.2389.

Keywords: *underwater image enhancement, GANs, attention mechanism, residual mechanism*

1. PENDAHULUAN

Citra bawah air sering mengalami penurunan kualitas yang disebabkan oleh proses redaman dan hamburan cahaya yang dipengaruhi oleh panjang gelombang serta jarak antara objek dan kamera (Li *et al.*, 2021). Faktor-faktor seperti gangguan pencahayaan dan kompleksitas latar bawah air sering kali menyebabkan citra menjadi buram, mengalami perubahan warna, dan mengalami berbagai bentuk degradasi visual lainnya. (Li *et al.*, 2020). Gambar yang terdegradasi kehilangan detail dan warna penting sehingga sulit untuk mengekstrak fitur gambar dan mendeteksi target (J. Zhou *et al.*, 2023). Degradasi kualitas citra bawah air umumnya ditandai dengan adanya distorsi warna akibat penyerapan cahaya oleh air, serta penurunan ketajaman visual yang disebabkan oleh hamburan cahaya oleh partikel tersuspensi seperti bahan organik, plankton, dan mikroorganisme lainnya yang tersebar dilingkungan perairan (Huang *et al.*, 2022). Cahaya di bawah air sebagian besar terdiri dari tiga jenis cahaya, cahaya langsung, cahaya penghamburan ke depan, dan cahaya penghamburan ke belakang. Cahaya merah menghilang terlebih dahulu, diikuti oleh cahaya hijau dan kemudian gambar bawah air akan dipenuhi dengan warna biru dan hijau. Penyerapan dan penghamburan menyebabkan bagian depan gambar tampak kabur, sementara kecerahan gambar berkurang saat cahaya menyebar ke belakang (Kumar *et al.*, 2023). Masalah-masalah tersebut menjadi tantangan yang berdampak negatif pada kualitas citra bawah air. Upaya peningkatan kualitas citra bawah air tidak hanya bertujuan untuk memperbaiki tampilan visual, tetapi juga untuk menghasilkan citra yang lebih baik sebagai masukan bagi proses pengolahan citra lanjutan. Keunikan dan kompleksitas dari citra bawah air membuat metode peningkatan konvensional yang dirancang untuk kondisi seperti cahaya rendah dan berkabut menjadi kurang efektif bila diterapkan dalam konteks bawah air (Li *et al.*, 2020; Cong, W. Yang, *et al.*, 2023; Kumar *et al.*, 2023). Bahkan beberapa proses yang dirancang khusus untuk tugas ini memberikan hasil yang tidak memuaskan dari segi kualitasnya (Huang *et al.*, 2022).

Dalam beberapa tahun terakhir, teknologi deep learning sangat mendorong perkembangan tugas *computer vision*, yang didalamnya (Cong, W. Yang, *et al.*, 2023) termasuk deteksi objek (Cong, N. Yang, *et al.*, 2023), analisis medis (Yue *et al.*, 2022), interpretasi penginderaan jauh (X. Zhou *et al.*, 2023), peningkatan konten (Wang *et al.*, 2022), dan peningkatan citra bawah air (Li, Guo and Guo, 2018). Di antara teknologi *deep learning*, *Generative Adversarial Networks* (GANs) menjadi salah satu metode yang telah mencapai kinerja yang mengejutkan dalam meningkatkan kualitas citra perceptual dari kumpulan data berpasangan atau tidak berpasangan (Cong, W. Yang, *et al.*, 2023; Islam, Xia

and Sattar, 2020). GANs awalnya diterapkan pada tugas *image style transfer* dan kemudian secara bertahap diterapkan pada berbagai bidang visual (Chakraborty *et al.*, 2024; Fabbri, Islam and Sattar, 2018; Krichen, 2023). GANs muncul sebagai pendekatan *deep learning* yang transformatif untuk menghasilkan data yang berkualitas tinggi dan beragam. Dalam GANs, generator menghasilkan data, sementara diskriminator mengevaluasi keaslian data yang dihasilkan. Melalui mekanisme *adversarial*, diskriminator belajar untuk membedakan antara data asli dan data palsu, sementara generator bertujuan untuk menghasilkan data yang tidak dapat dibedakan dari data asli (Chakraborty *et al.*, 2024; Marasakatla *et al.*, 2023). Aplikasi sukses GANs dalam banyak tugas visual memberikan solusi baru untuk mengatasi masalah peningkatan citra bawah air. Li et al. mengusulkan WaterGAN, yang mentransfer gaya gambar normal dan gambar bawah air untuk mencapai tujuan peningkatan gambar. Arjovsky et al. memanfaatkan Wasserstein GAN dengan penalti gradien, digunakan untuk secara langsung meningkatkan gambar bawah air yang terdistorsi. Islam et al. membangun FUNIE-GAN berdasarkan U-Net dengan menggabungkan berbagai fungsi kerugian dan mewujudkan efek peningkatan *real-time*. Disebabkan skala parameter yang kecil, generator berdasarkan U-Net memproses gambar dengan cepat, tetapi fitur yang diekstraksi tidak sebaik jaringan dalam dengan parameter besar, dan masih ada ruang untuk peningkatan lebih lanjut dalam pemanfaatan fitur. Selain GANs, model *residual* berbasis CNN juga memiliki kinerja yang baik. Kedua model melaporkan kemajuan yang menginspirasi untuk peningkatan warna, penghilangan kabut, dan penyesuaian kontras (Marasakatla *et al.*, 2023; Zaidi, Singh and Guha, 2024). Namun, masih ada ruang yang signifikan untuk perbaikan karena mempelajari peningkatan perceptual untuk citra bawah air adalah masalah yang lebih menantang dan tidak terdefinisi dengan baik jika dibandingkan dengan citra terestrisl (Islam, Xia and Sattar, 2020).

Penggunaan *attention* dan *residual mechanism* memungkinkan jaringan untuk fokus pada bagian penting dari gambar dan membantu dalam pemulihhan informasi yang hilang selama proses peningkatan gambar (Huang *et al.*, 2022; Chang, Gao and Zhang, 2023). Penelitian ini menggunakan GANs untuk peningkatan gambar bawah air yang melibatkan *attention* dan *residual mechanism* pada bagian generator. Bagian generator akan dirancang dengan menggunakan *residual block* untuk mempertahankan informasi struktural dan *attention mechanism* untuk berfokus pada area penting dari gambar bawah air dengan harapan dapat membantu dalam meningkatkan kualitas visual gambar bawah air dengan lebih efektif sehingga menghasilkan gambar yang jelas dan alami. Kontribusi utama dari penelitian

ini yaitu pengembangan arsitektur generator baru, dimana arsitekturnya berbasis *residual block* yang dilengkapi dengan *channel attention* dan *spatial attention* yang bertujuan untuk mempertahankan informasi struktural penting dari gambar asli, memfokuskan proses peningkatan pada bagian gambar yang mengalami degradasi parah, dan meningkatkan efisiensi pemulihan warna alami dan kontras secara lokal. Selain itu, penambahan *attention module* memungkinkan jaringan untuk mendeteksi area penting dalam gambar secara adaptif, sehingga membantu meningkatkan kejernihan (clarity) dan estetika gambar asli.

2. METODE PENELITIAN

Penelitian ini menggunakan dataset EUVP atau *Enhancing Underwater Visual Perception dataset* yang berisi kumpulan sampel gambar berpasangan dan tidak berpasangan yang terpisah dengan kualitas persepsi yang buruk dan baik untuk memfasilitasi pelatihan model peningkatan gambar bawah air. Penelitian ini menggunakan dataset gambar berpasangan *underwater dark* yang disediakan oleh EUVP. Jumlah total citra berpasangan dalam subset *underwater dark* adalah 5550 citra sehingga jumlah citra yang dilatih sebanyak 3330 citra (60%), dengan 1110 citra (20%) untuk pengujian dan 1110 citra (20%) untuk validasi.

Penelitian ini menggunakan GANs dengan modifikasi yang dilakukan pada bagian generator dan diskriminator. Generator bertugas untuk meningkatkan kualitas citra bawah air, dan diskriminator bertugas untuk membedakan apakah citra hasil generator adalah nyata (*real*) atau sesuai dengan citra referensi atau palsu (*fake*). Pada gambar 1 terlihat alur kerja dari GANs yang diusulkan dalam penelitian ini. Proses peningkatan citra diawali dengan citra masukan yang berupa citra bawah air yang mengalami distorsi warna, kontras rendah, dan kabut atau *noise*. Citra masukan akan diproses dalam generator. Generator terdiri dari beberapa modul khusus untuk meningkatkan kualitas citra.

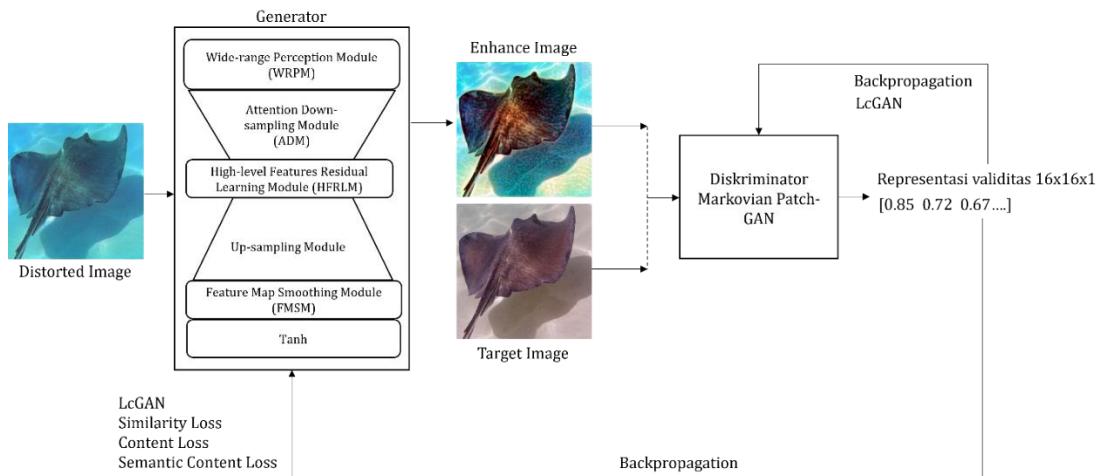
Seperti yang ditunjukkan pada gambar 2, bagian generator pada penelitian ini dirancang menggunakan *residual block* dan *attention block* yang terdiri dari *wide-range perception module* (WRPM), *attention down-sampling module* (ADM), *high-level features residual-learning module* (HFRLM), *up-sampling module* (UM), dan *feature map smoothing module* (FMSM) yang diikuti oleh tanh *activation layer*. Bagian WRPM terdiri dari *reflection padding layer*, lapisan konvolusi dengan ukuran 7x7, lapisan normalisasi, dan lapisan aktivasi non-linear. WRPM memperoleh konteks global dari citra melalui *receptive field* yang berguna untuk memahami pola global atau informasi spasial dalam citra. ADM terdiri dari beberapa blok, dimana setiap blok mengandung 4x4 lapisan konvolusi dengan sebuah *stride* dan *padding*, diikuti sebuah lapisan

normalisasi, lapisan aktivasi, dan sebuah *attention module*. ADM melakukan *downsampling* sambil menekankan bagian penting citra menggunakan mekanisme *attention*. Memastikan bahwa fitur penting tetap dipertahankan meskipun resolusi diturunkan. Setelah *down-sampling*, selanjutnya akan diteruskan ke HFRLM yang terdiri dari beberapa *residual blocks*. Setiap *residual blocks* mengandung dua lapisan konvolusi dengan *padding layers*. HFRLM menyediakan jalur *residual learning* untuk menjaga stabilitas pelatihan dan mempelajari representasi fitur tingkat tinggi. Sehingga membantu menangkap informasi mendalam dari citra seperti tepi dan tekstur. Setelah HFRLM, proses akan dilanjutkan ke UM. UM terdiri dari beberapa *up-sampling blocks*. Setiap *up-sampling blocks* mengandung sebuah *convolutional transpose layer* dengan ukuran kernel 4x4. *Up-sampling module* mengembalikan citra ke resolusi semula setelah sebelumnya dilakukan *downsampling*. Setelah *up-sampling*, dilanjutkan ke FMSM yang terdiri dari sebuah *reflection padding layer* dan sebuah lapisan konvolusi dengan ukuran 7x7. Proses ini dilakukan karena gambar yang ditingkatkan menunjukkan berbagai tingkat *checkerboard artifacts*. Operasi konvolusi dengan kernel besar, dapat menghaluskan *feature map* dan mengurangi terjadinya *noise*. Hal ini juga dapat membuat gambar yang di *up-sampling* menjadi lebih alami dengan perbaikan warna dan kontur. Sehingga meningkatkan kualitas visual *output*. Hasil dari generator adalah citra bawah air yang telah diperbaiki.

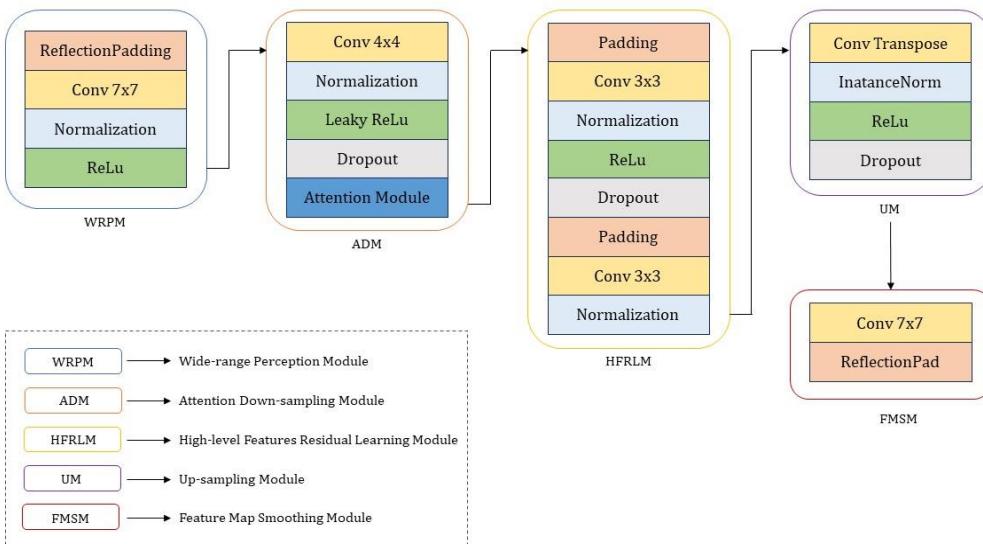
Proses setelah generator adalah diskriminator. Diskriminator menerima citra hasil generator dan citra referensi (*ground truth*), lalu mencoba membedakan keduanya. Generator berusaha menipu diskriminator dengan menghasilkan citra yang mendekati *ground truth*. Namun diskriminator dilatih untuk mengenali citra hasil generator atau citra palsu. Sehingga ketika diskriminator mampu mengenali citra hasil generator maka akan terjadinya *backpropagation*, dimana generator akan diperbarui menggunakan *generator loss* dan diskriminator akan diperbarui menggunakan *discriminator loss*. Gambar 3 menunjukkan proses yang terjadi dalam diskriminator. Diskriminator dirancang dengan menggunakan arsitektur Markovian PatchGAN yang mengasumsikan independensi piksel di luar ukuran *patch*, yaitu hanya mendiskriminasi berdasarkan informasi tingkat *patch*. Asumsi ini penting karena secara efektif dapat menangkap fitur dengan frekuensi tinggi seperti tekstur dan *local style*. Selain itu, konfigurasi ini lebih efisien secara komputasi karena membutuhkan lebih sedikit parameter dibandingkan dengan mendiskriminasi secara global pada tingkat gambar. Jadi diskriminator dengan PatchGAN yaitu diskriminator yang menilai *real* atau *fake* pada *patch* kecil (blok-blok kecil), bukan keseluruhan citra.

Arsitekturnya terdiri dari empat lapisan konvolusi yang mengubah input $256 \times 256 \times 6$ gambar nyata dan gambar yang dihasilkan menjadi *output* $16 \times 16 \times 1$

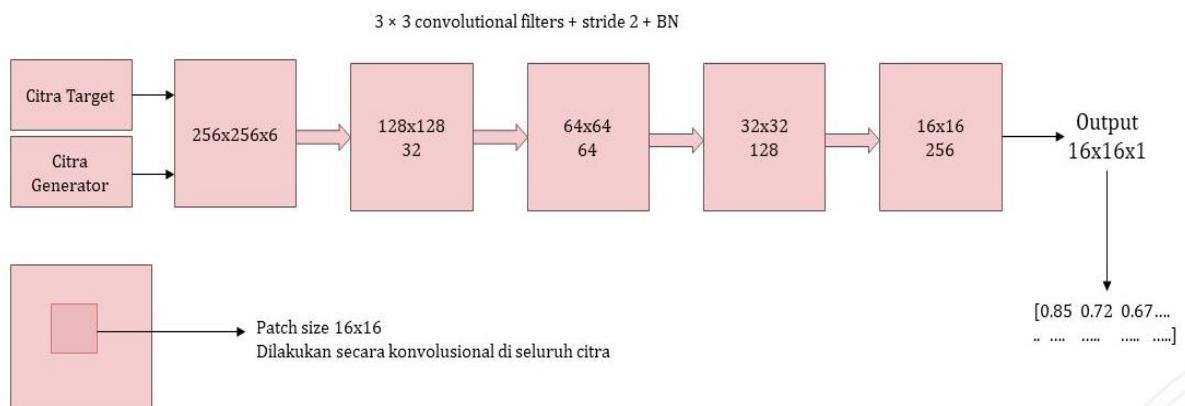
yang mewakili respon validitas rata-rata dari diskriminatator.



Gambar 1 Alur GANs yang Diusulkan



Gambar 1 Rancangan Arsitektur Generator yang Digunakan



Gambar 3 Rancangan Diskriminatator yang Digunakan (Markovian PatchGAN)

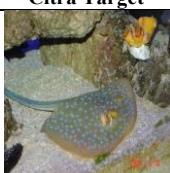
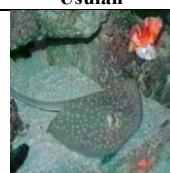
3. HASIL DAN PEMBAHASAN

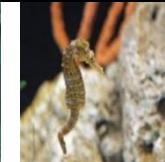
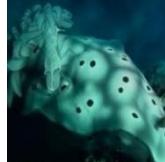
Penelitian ini di evaluasi dengan menggunakan metrik evaluasi seperti *peak-signal to noise ratio* (PSNR), *structural similarity index* (SSIM), *underwater image quality measure* (UIQM), dan *underwater color image quality evaluation* (UCIQE) yang digunakan untuk mengevaluasi masing-masing gambar pada data uji dan pada keseluruhan data uji.

Hasil yang ditunjukkan pada tabel 1 menunjukkan beberapa gambar yang dihasilkan oleh FUnIE-GAN (Islam, Xia and Sattar, 2020), RAUNE-Net (Peng *et al.*, 2023), dan metode yang diusulkan oleh penelitian ini. Dari hasil gambar yang ditampilkan, terlihat bahwa FUnIE-GAN menghasilkan gambar yang lebih berwarna dibandingkan dua metode lainnya. Namun, gambar-gambar tersebut menunjukkan artefak warna yang berlebihan dan kurang mempertahankan tekstur alami. Sementara itu, RAUNE-Net menunjukkan

perbaikan dalam hal mempertahankan tekstur jika dibandingkan dengan FUnIE-GAN, akan tetapi warna yang dihasilkan masih tampak kurang alami jika dibandingkan dengan gambar target. Kemudian untuk gambar yang dihasilkan oleh metode yang diusulkan dalam penelitian ini menunjukkan hasil yang paling mendekati gambar target. Gambar yang dihasilkan tampak lebih alami dengan warna yang lebih akurat dan detail yang lebih baik. Namun jika dibandingkan berdasarkan hasil evaluasi, ketiganya memiliki perbedaan hasil. FUnIE-GAN cenderung memiliki nilai PSNR yang lebih baik dalam beberapa gambar dibandingkan dengan RAUNE-Net dan metode usulan. Sedangkan untuk nilai SSIM, FUnIE-GAN mencapai nilai yang kurang baik jika dibandingkan dengan dua metode lainnya. Artinya RAUNE-Net dan metode usulan memiliki kualitas gambar yang lebih baik dan sangat mirip dengan gambar targetnya.

Tabel 1. Hasil Evaluasi Beberapa Gambar

Citra Buruk	Citra Target	FUnIE-GAN	RAUNE-Net	Usulan
				
SSIM		0.5627	0.6201	0.6733
PSNR		19.514	20.038	27.072
UCIQE		0.4172	0.1859	0.8735
UIQM		1.1593	1.0255	0.9893
Citra Buruk	Citra Target	FUnIE-GAN	RAUNE-Net	Usulan
				
SSIM		0.7184	0.7625	0.7519
PSNR		26.646	27.331	25.295
UCIQE		0.1409	0.0902	0.1251
UIQM		1.8019	1.7234	1.6192
				
SSIM		0.8350	0.9129	0.9060
PSNR		33.076	34.875	32.533
UCIQE		0.2613	0.2019	0.1807
UIQM		1.3249	1.3801	1.3471
				
SSIM		0.7819	0.8697	0.8659
PSNR		33.029	26.729	30.152
UCIQE		0.2454	0.1966	0.2588
UIQM		1.0599	1.1601	1.0427

	Citra Buruk	Citra Target	FUNIE-GAN	RAUNE-Net	Usulan
					
SSIM		0.8576	0.9085		0.8712
PSNR		34.430	30.414		27.109
UCIQE		0.2447	0.1541		0.1843
UIQM		1.8223	1.8491		1.7510
					
SSIM	0.8743	0.9098	0.8977	SSIM	
PSNR	30.096	25.914	28.227	PSNR	
UCIQE	0.1278	0.0997	0.1233	UCIQE	
UIQM	2.1551	2.2826	2.2269	UIQM	
					
SSIM		0.7706	0.8915		0.8081
PSNR		32.863	28.262		28.852
UCIQE		0.3079	0.1833		0.1990
UIQM		1.1343	1.1764		1.1888
					
SSIM		0.7353	0.7097		0.7918
PSNR		27.428	25.508		26.857
UCIQE		0.2039	0.1544		0.1764
UIQM		1.1192	1.1136		1.1382
					
SSIM		0.6818	0.7261		0.7126
PSNR		26.519	22.871		23.999
UCIQE		0.2626	0.1372		0.1522
UIQM		1.0096	1.2253		1.1924

Tabel 2. Hasil Evaluasi Keseluruhan

Tabel 2. Hasil Evaluasi Keteraturan				
Metode	PSNR	SSIM	UIQM	UCIQE
FUnIEGAN	25.1279	0.6992	1.4531	0.2567
RAUNE-Net	23.2689	0.7603	1.5066	0.1559
Proposed	23.7966	0.7219	1.4485	0.2389

Hasil evaluasi untuk keseluruhan gambar pada data tes juga dihitung dan kemudian dilihat perbandingan hasil yang diperoleh. Tabel 2 menunjukkan perbandingan rata-rata dari hasil tes pada dataset EUVP. FUNIE-GAN memiliki nilai PSNR dan UCIQE yang tinggi, yang menunjukkan bahwa kualitas gambar yang dihasilkan membaik dalam hal kejernihan dan kontras. Namun, nilai SSIM

yang diraih menunjukkan bahwa gambar tidak terlalu baik dalam hal kesamaan struktural dan kualitas gambar alami. Sementara, RAUNE-Net memiliki hasil SSIM dan UIQM yang tertinggi dibandingkan dua metode lainnya. Hal ini menunjukkan bahwa RAUNE-Net menghasilkan gambar yang paling mirip secara structural dengan gambar target dan juga memiliki kualitas visual yang lebih baik. Akan tetapi

nilai PSNR dan UCIQE yang lebih rendah menunjukkan bahwa terdapat lebih banyak *noise* dan kurangnya kontras jika dibandingkan dengan dua metode lainnya. Kemudian untuk metode yang diusulkan, nilai PSNR yang diperoleh lebih baik dari RAUNE-Net dan nilai SSIM yang dicapai lebih tinggi dari FUnIE-GAN yang berarti bahwa kualitas gambar menjadi lebih baik dan memiliki kemiripan struktural yang sangat baik dengan gambar target. Namun dengan nilai UIQM yang dicapai, menunjukkan bahwa gambar yang dihasilkan belum mencapai kualitas visual yang optimal dalam hal kontras, warna, dan ketajaman. Akan tetapi, gambar yang dihasilkan oleh metode usulan memiliki nilai evaluasi yang cukup baik. Nilai evaluasi SSIM, PSNR, dan UCIQE menjadi nilai tertinggi kedua, sementara FUnIE-GAN dan RAUNE-Net hanya mencapai nilai evaluasi tertinggi pada dua metrik evaluasi. Hal ini menunjukkan bahwa gambar yang dihasilkan memiliki kualitas alami yang lebih baik dan menghasilkan lebih sedikit *noise*. Sehingga dari hasil yang ditunjukkan pada tabel 2, dapat disimpulkan bahwa FUnIE-GAN unggul dalam hal kejernihan dan kontras gambar akan tetapi memiliki kekurangan yaitu dalam hal kesamaan struktural dan kualitas alami gambar. RAUNE-Net memiliki keunggulan dalam hal kesamaan structural dan kualitas visual, namun memiliki kelemahan dalam hal kejernihan dan kontras gambar. Sementara, metode usulan menawarkan keseimbangan kinerja dengan kualitas alami gambar yang sangat baik, meskipun kualitas visual keseluruhan sedikit lebih rendah dari dua metode lainnya.

4. KESIMPULAN

Penelitian ini melakukan evaluasi pada dua metode yang sudah ada sebelumnya yaitu FUnIE-GAN dan RAUNE-Net untuk dibandingkan dengan hasil metode yang diusulkan dalam penelitian ini. Evaluasi dilakukan dengan menggunakan beberapa metrik evaluasi seperti SSIM, PSNR, UIQM, UCIQE, dan NIQE. Hasil penelitian yang ditampilkan pada tabel 1 dan 2 membuktikan bahwa FUnIE-GAN menghasilkan gambar yang lebih berwarna sehingga menimbulkan artefak warna yang berlebihan dan kurang mempertahankan tekstur alami. Sehingga gambar yang dihasilkan terlihat tidak alami dan warna yang dihasilkan sedikit jauh dari gambar target. FUnIEGAN unggul dalam hal kejernihan dan kontras gambar karena memiliki nilai PSNR dan UCIQE yang cukup tinggi. Sementara, RAUNE-Net memiliki nilai SSIM dan UIQM yang tinggi dibandingkan dengan FUnIEGAN dan metode yang diusulkan, yang menandakan bahwa RAUNE-Net menghasilkan gambar dengan kesamaan struktural yang cukup baik hingga mendekati gambar target dan memiliki kualitas visual yang juga baik. Meskipun gambar yang dihasilkan lebih baik dalam hal tekstur, tetapi kurang alami dalam hal warna dan juga

memiliki nilai PSNR dan UCIQE yang rendah yang menandakan bahwa RAUNE-Net lemah dalam hal kejernihan dan kontras gambar. Sementara itu, metode usulan merupakan modifikasi dari GANs yang dilakukan dengan menggabungkan *attention* dan *residual mechanism* pada bagian generator dan menggunakan Markovian PatchGAN pada bagian discriminator. Hal ini dilakukan agar dapat menghasilkan gambar yang lebih alami dari segi warna, namun juga tetap dapat meningkatkan kualitas gambar. Hasil evaluasi menunjukkan nilai PSNR dan UCIQE mencapai nilai yang lebih tinggi dibandingkan dengan RAUNE-Net. Kemudian nilai SSIM yang diperoleh mencapai nilai yang lebih tinggi jika dibandingkan dengan FUnIE-GAN. Hal ini menunjukkan adanya keseimbangan kinerja dengan kualitas gambar yang dapat ditingkatkan yang juga dibuktikan dengan nilai NIQE yang sangat rendah. Gambar yang dihasilkan juga mendekati gambar target dengan warna yang lebih akurat dan detail yang lebih baik. Secara keseluruhan, ketiga metode yang dilatih dengan dataset yang sama memiliki keunggulan dan kekurangan masing-masing.

Metode usulan menghasilkan warna yang lebih alami dan tidak berlebihan seperti yang dihasilkan oleh FUnIE-GAN. FUnIE-GAN dirancang untuk berfokus pada restorasi warna yang hilang atau terdistorsi akibat dari kondisi lingkungan bawah air. Metode ini mengimplementasikan teknik pemetaan warna untuk mengembalikan warna asli gambar yang akhirnya membuat gambar yang dihasilkan menjadi lebih berwarna. Sementara RAUNE-Net dirancang untuk dapat mempertahankan struktur dan tekstur alami gambar asli sebaik mungkin sehingga menjadikannya lebih fokus pada informasi spasial dan tekstural daripada informasi warna, yang pada akhirnya menyebabkan gambar yang dihasilkan cenderung menjadi *grayscale*. FUnIE-GAN yang lebih berwarna dan RAUNE-Net yang cenderung menjadi grayscale, dapat diatasi oleh metode usulan dalam penelitian ini hingga gambar yang dihasilkan selama proses pelatihan maupun tes menjadi berwarna namun tetap terlihat alami seperti citra targetnya. Warna yang dimiliki tidak berlebihan namun juga tidak sepenuhnya menjadi grayscale. Gambar yang dihasilkan memiliki keseimbangan yang cukup baik antara kualitas alami gambar dan kesamaan struktural dengan citra target. Metode usulan dalam penelitian ini dapat menyeimbangkan pemulihan warna dan preservasi tekstur sehingga menghasilkan gambar yang lebih alami dan realistik, tanpa artefak warna yang berlebihan atau kehilangan detail tekstur. Tanpa artefak warna artinya citra yang dihasilkan tidak menimbulkan warna-warna baru pada objek ataupun pada *background* citra. Contoh citra dengan artefak warna yang berlebihan dapat dilihat pada hasil citra dari FUnIE-GAN. Dimana hasil citranya terlihat memiliki warna-warna baru yang tidak diinginkan seperti warna kuning, ungu,

biru, dan sebagainya. Sementara itu, tanpa kehilangan detail tekstur artinya model tidak melakukan penghilangan *noise* secara ekstrem sehingga tidak menghapus fitur tekstur bersama dengan *noise*. Fitur-fitur dalam citra tetap terjaga. Kelemahan dari metode ini sama dengan kelemahan yang terdapat pada FUNIE-GAN yang terletak pada kualitas visual keseluruhan dari gambar yang dihasilkan baik dari segi ketajaman, warna, dan kontras yang dibuktikan dengan rendahnya nilai UIQM yang dicapai keduanya. Namun kelebihan dari metode yang diusulkan dapat dilihat dari gambar yang dihasilkan dan hasil perhitungan metrik evaluasi. Gambar menghasilkan warna yang terlihat lebih alami dan kualitas yang meningkat yang dibuktikan dengan hasil perhitungan kelima metrik evaluasi.

Rencana ke depan yang ingin dilakukan yaitu melakukan optimasi lebih lanjut pada metode yang diusulkan untuk meningkatkan kualitas citra bawah air tanpa perlu mengorbankan kualitas alami gambar karena pada penelitian ini nilai UIQM yang dicapai masih tergolong rendah. Menggunakan dataset yang bervariasi untuk menguji generalisasi metode yang diusulkan. Serta menguji pada berbagai kondisi pencahayaan dan kedalaman untuk memastikan metode yang diusulkan dapat bekerja secara konsisten di berbagai situasi. Selain itu, rencana lain yang ingin dilakukan ke depannya adalah melakukan uji subjektif dengan melibatkan ahli dalam bidang pengolahan gambar bawah air untuk mendapatkan umpan balik kualitatif.

DAFTAR PUSTAKA

- CHAKRABORTY, T. *et al.* 2024 ‘Ten years of generative adversarial nets (GANs): a survey of the state-of-the-art’, *Machine Learning: Science and Technology*, 5(1), pp. 1–29. Available at: <https://doi.org/10.1088/2632-2153/ad1f77>.
- CONG, R., YANG, N., *et al.* 2023 ‘Global-and-Local Collaborative Learning for Co-Salient Object Detection’, *IEEE Transactions on Cybernetics*, 53(3), pp. 1920–1931. Available at: <https://doi.org/10.1109/TCYB.2022.316943> 1.
- CONG, R., YANG, W., *et al.* 2023 ‘PUGAN: Physical Model-Guided Underwater Image Enhancement Using GAN With Dual-Discriminators’, *IEEE Transactions on Image Processing*, 32, pp. 4472–4485. Available at: <https://doi.org/10.1109/TIP.2023.3286263>.
- FABBRI, C., ISLAM, M.J. AND SATTAR, J. 2018 ‘Enhancing Underwater Imagery Using Generative Adversarial Networks’, *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 7159–7165. Available at: <https://doi.org/10.1109/ICRA.2018.846055> 2.
- HUANG, Z. *et al.* 2022 ‘Underwater Image Enhancement via Adaptive Group Attention-Based Multiscale Cascade Transformer’, *IEEE Transactions on Instrumentation and Measurement*, 71, pp. 1–18. Available at: <https://doi.org/10.1109/TIM.2022.3189630>.
- ISLAM, M.J., XIA, Y. AND SATTAR, J. 2020 ‘Fast Underwater Image Enhancement for Improved Visual Perception’, *IEEE Robotics and Automation Letters*, 5(2), pp. 3227–3234. Available at: <https://doi.org/10.1109/LRA.2020.2974710>.
- KRICHEN, M. 2023 ‘Generative Adversarial Networks’, *2023 14th International Conference on Computing Communication and Networking Technologies, ICCCNT 2023*, pp. 1–7. Available at: <https://doi.org/10.1109/ICCCNT56998.2023.10306417>.
- KUMAR, N. *et al.* 2023 ‘Underwater Image Enhancement using Deep Learning’, *Multimedia Tools and Applications*, 82(30), pp. 46789–46809. Available at: <https://doi.org/10.1007/s11042-023-15525-4>.
- LI, C. *et al.* 2020 ‘An Underwater Image Enhancement Benchmark Dataset and beyond’, *IEEE Transactions on Image Processing*, 29, pp. 4376–4389. Available at: <https://doi.org/10.1109/TIP.2019.2955241>.
- LI, C. *et al.* 2021 ‘Underwater Image Enhancement via Medium Transmission-Guided Multi-Color Space Embedding’, *IEEE Transactions on Image Processing*, 30, pp. 4985–5000. Available at: <https://doi.org/10.1109/TIP.2021.3076367>.
- LI, C., GUO, J. AND GUO, C. 2018 ‘Emerging from Water: Underwater Image Color Correction Based on Weakly Supervised Color Transfer’, *IEEE Signal Processing Letters*, 25(3), pp. 323–327. Available at: <https://doi.org/10.1109/LSP.2018.2792050>.
- MARASAKATLA, D. *et al.* 2023 ‘Under Water Image Enhancement Using CNN’, *IEEE International Conference on Advances in Electronics, Communication, Computing and Intelligent Information Systems, ICAECIS 2023 - Proceedings*, pp. 211–217. Available at: <https://doi.org/10.1109/ICAECIS58353.2023.10170509>.
- PENG, W. *et al.* 2023 ‘RAUNE-Net: A Residual and

- Attention-Driven Underwater Image Enhancement Method', 1. Available at: <http://arxiv.org/abs/2311.00246>.
- WANG, Z. *et al.* 2022 'Adaptive feature fusion network based on boosted attention mechanism for single image dehazing', *Multimedia Tools and Applications*, 81(8), pp. 11325–11339. Available at: <https://doi.org/10.1007/s11042-022-12151-4>.
- YUE, G. *et al.* 2022 'Boundary Constraint Network With Cross Layer Feature Integration for Polyp Segmentation', *IEEE Journal of Biomedical and Health Informatics*, 26(8), pp. 4090–4099. Available at: <https://doi.org/10.1109/JBHI.2022.3173948>.
- ZAIDI, S., SINGH, P. AND GUHA, P. 2024 'Designing a U-Net Architecture for Underwater Image Enhancement', *2024 National Conference on Communications, NCC 2024*, pp. 1–6. Available at: <https://doi.org/10.1109/NCC60321.2024.10485836>.
- ZHOU, J. *et al.* 2023 'Multi-view underwater image enhancement method via embedded fusion mechanism', *Engineering Applications of Artificial Intelligence*, 121(February), p. 105946. Available at: <https://doi.org/10.1016/j.engappai.2023.105946>.
- ZHOU, X. *et al.* 2023 'Edge-Guided Recurrent Positioning Network for Salient Object Detection in Optical Remote Sensing Images', *IEEE Transactions on Cybernetics*, 53(1), pp. 539–552. Available at: <https://doi.org/10.1109/TCYB.2022.3163152>.

Halaman ini sengaja dikosongan