

PEMULIHAN CITRA AKIBAT DEGRADASI DIGITAL MENGGUNAKAN PIX2PIX *GENERATIVE ADVERSARIAL NETWORKS* (GAN)

Minan Abdillah^{1*}, Sri Mulyono²

^{1,2}Teknik Informatika, Universitas Islam Sultan Agung

minanabdillah4@gmail.com^{1*} sri.m@unissula.ac.id²

Received: 10-08- 2025

Revised: 15-08-2025

Approved: 23-08-2025

ABSTRAK

Kerusakan digital pada citra dapat menghilangkan detail penting dan menurunkan kualitas visual. Penelitian ini bertujuan mengembangkan sistem restorasi citra berbasis Pix2Pix Generative Adversarial Networks (GAN) dengan U-Net sebagai Generator dan PatchGAN sebagai Discriminator. Dataset yang digunakan adalah CelebA-HQ beresolusi 256×256 pixel yang dimodifikasi menjadi tiga tingkat kerusakan yaitu ringan, sedang, dan berat. Proses pelatihan dilakukan selama 100 epoch menggunakan optimizer Adam dengan penyesuaian rasio pembaruan Generator-Discriminator (1:1, 2:1, dan 3:1) untuk menjaga stabilitas model. Evaluasi dilakukan menggunakan Structural Similarity Index Measure (SSIM) dan Peak Signal-to-Noise Ratio (PSNR). Hasil menunjukkan model mampu mencapai SSIM 0,9226 dan PSNR 32,68 dB, yang menandakan keberhasilan dalam mempertahankan struktur spasial serta meningkatkan kualitas visual citra hasil restorasi. Pengujian pada tiga kategori kerusakan menunjukkan tingkat keberhasilan rata-rata di atas 90% pada kerusakan ringan dan sedang, serta 85–90% pada kerusakan berat, meskipun detail halus seperti hidung dan rambut belum sepenuhnya sempurna. Dibandingkan metode konvensional, pendekatan GAN terbukti lebih efektif dalam menghasilkan citra yang realistis dan natural. Selain itu, sistem diimplementasikan dalam bentuk aplikasi web yang memudahkan pengguna melakukan unggah, restorasi, dan unduh citra secara praktis. Dengan demikian, penelitian ini menyimpulkan bahwa pendekatan Pix2Pix berbasis GAN efektif untuk pemulihan citra digital dan memiliki potensi untuk dikembangkan lebih lanjut pada berbagai domain citra termasuk medis maupun arsip sejarah digital.

Kata Kunci : Restorasi, GAN, Pix2Pix, SSIM, PSNR

PENDAHULUAN

Fotografi digital memiliki peran penting dalam berbagai bidang, mulai dari dokumentasi sejarah, pelestarian budaya, identifikasi forensik, hingga analisis medis. Namun, kualitas citra sering mengalami degradasi akibat kompresi berlebihan, resolusi rendah, maupun artefak visual seperti blocking, noise, dan distorsi warna yang dapat mengurangi ketajaman detail serta mengaburkan informasi penting [1][2]. Kondisi ini menegaskan perlunya metode restorasi citra yang mampu mengembalikan kualitas visual agar tetap bernilai informatif dan fungsional pada berbagai aplikasi [3].

Berbagai pendekatan telah dikembangkan untuk mengatasi masalah tersebut, mulai dari metode interpolasi bilinear dan bicubic hingga *image inpainting*. Namun, metode konvensional terbukti kurang efektif dalam menjaga detail spasial dan tekstur pada citra dengan kerusakan kompleks [4][5]. Pendekatan berbasis *deep learning*, khususnya *Generative Adversarial Networks* (GANs), menjadi solusi yang lebih adaptif karena mampu mempelajari representasi data secara mendalam serta menghasilkan keluaran yang lebih realistis [6][7]. Teknologi ini juga telah diterapkan secara luas, mulai dari restorasi citra medis hingga rekonstruksi citra forensik [8][9].

Salah satu model GAN yang menonjol adalah Pix2Pix, yang bekerja pada kerangka *image-to-image translation* berbasis pasangan citra input dan target [10]. Arsitektur ini menggabungkan U-Net pada *Generator* untuk mempertahankan detail spasial dan PatchGAN pada *Discriminator* untuk mengevaluasi realisme secara lokal [11][12]. Berbagai studi membuktikan bahwa Pix2Pix efektif meningkatkan kualitas

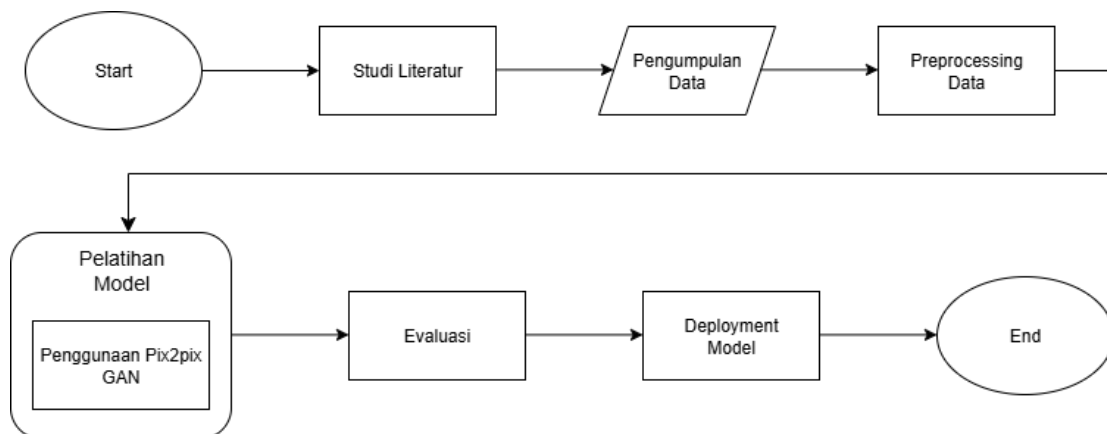
restorasi citra wajah dengan peningkatan signifikan pada metrik PSNR dan SSIM [13][14]. Penelitian lebih lanjut juga mengintegrasikan *perceptual loss* dan *style loss* guna memperbaiki kualitas visual hasil rekonstruksi (Ren dkk., 2024; Ma, 2024).

Meski menjanjikan, penerapan GAN dalam restorasi citra menghadapi sejumlah tantangan, di antaranya ketidakstabilan pelatihan, *mode collapse*, dan ketergantungan pada dataset berkualitas tinggi [15]. Upaya untuk mengatasi hal ini meliputi pengembangan varian seperti WGAN-GP dengan *gradient penalty* atau normalisasi spektral pada *Discriminator* untuk menjaga stabilitas [16][17]. Selain itu, strategi *uncertainty prediction* pada level *pixel* juga diusulkan untuk meningkatkan akurasi pada bagian citra yang rusak parah [18].

Berdasarkan kajian literatur, pemanfaatan GAN, khususnya arsitektur Pix2Pix, memiliki potensi besar dalam mengatasi degradasi citra digital, terutama pada citra wajah yang sarat dengan detail halus dan struktur kompleks. Penelitian ini difokuskan pada pengembangan sistem restorasi citra berbasis Pix2Pix GAN menggunakan dataset CelebA-HQ beresolusi 256×256 dengan tiga tingkat kerusakan, serta evaluasi performa menggunakan metrik SSIM dan PSNR. Sistem yang dihasilkan juga diimplementasikan dalam bentuk aplikasi berbasis web untuk memudahkan penggunaan praktis [19][20]. Dengan demikian, masalah utama penelitian ini adalah bagaimana merancang sistem restorasi citra yang mampu mengatasi berbagai bentuk kerusakan digital secara efektif, menjaga detail penting pada citra wajah, serta menghasilkan keluaran yang stabil dan realistis dibandingkan metode konvensional.

METODE PENELITIAN

Dalam penelitian ini akan dilakukan serangkaian proses untuk membangun sistem restorasi citra berbasis deep learning dengan model GAN yang terdiri dari *Generator* berarsitektur U-net dan *Discriminator* PatchGAN. Sistem ini dirancang untuk memproses citra yang mengalami kerusakan dan memulihkannya agar menyerupai kondisi aslinya. Tahapan meliputi kajian literatur, pengumpulan Dataset, preprocessing, pelatihan model, evaluasi hasil, dan *deployment* model yang dapat dilihat pada Gambar 1.



Gambar 1 Tahapan Penelitian

Pengumpulan Data

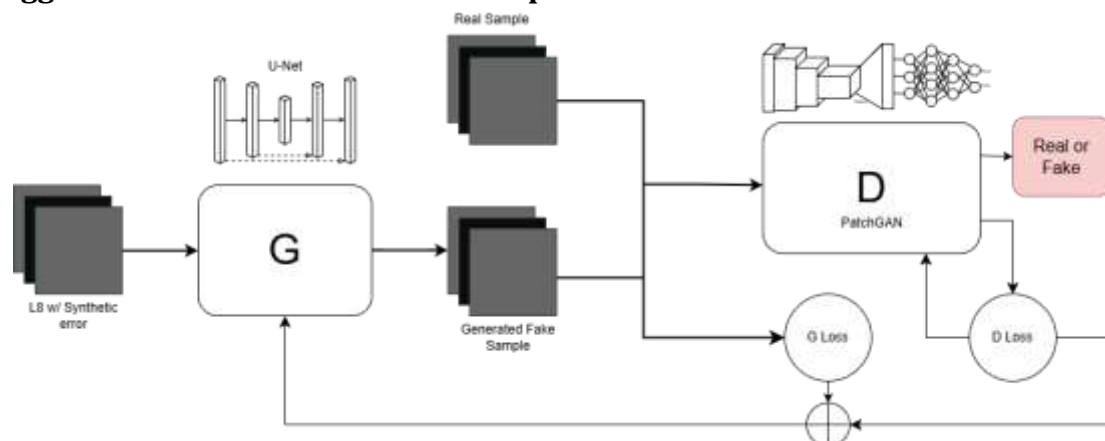
Dataset yang digunakan adalah CelebA-HQ *resized* (256 x 256), yang berisi citra wajah beresolusi tinggi dengan variasi ekspresi, usia, pencahayaan, dan sudut pandang. Dataset ini dipilih karena memiliki keberagaman yang cukup luas sehingga dapat merepresentasikan kondisi nyata dari citra wajah pada berbagai situasi. Untuk kebutuhan penelitian, citra asli dimodifikasi secara terkontrol menjadi tiga tingkat

kerusakan, yaitu ringan, sedang, dan berat. Kerusakan ringan ditandai dengan munculnya noise dan goresan halus, kerusakan sedang mencakup bagian wajah yang hilang sebagian, sedangkan kerusakan berat menyebabkan hilangnya detail wajah secara signifikan. Dengan adanya tiga variasi tingkat degradasi ini, sistem dapat diuji kemampuannya dalam memulihkan citra dari kondisi yang sederhana hingga kompleks.

Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan dataset berada dalam kondisi yang seragam dan siap digunakan oleh arsitektur Pix2Pix. Proses diawali dengan pengurutan file citra agar pasangan antara citra rusak dan citra asli sesuai, sehingga tidak terjadi kesalahan dalam proses pelatihan. Selanjutnya, seluruh citra dikonversi ke format RGB 3-channel agar kompatibel dengan struktur jaringan konvolusional yang digunakan pada *Generator* dan *Discriminator*. Setelah itu, dilakukan normalisasi nilai *pixel* ke rentang $[-1, 1]$ dengan tujuan mempercepat proses konvergensi model sekaligus menjaga stabilitas selama pelatihan. Tahap terakhir adalah validasi data, yaitu pemeriksaan konsistensi jumlah file antara citra input dan target, serta memastikan tidak terdapat citra yang hilang atau rusak. Melalui tahapan ini, dataset menjadi lebih terstruktur, memiliki format warna yang seragam, dan siap digunakan dalam proses pelatihan model.

Penggunaan dan Pelatihan Model Pix2pix



Gambar 2 Arsitektur Model pix2pix

Pada Gambar 2 ditunjukkan arsitektur Pix2Pix, yaitu varian *Generative Adversarial Networks* (GAN) berbasis metode supervised untuk *image-to-image translation* dengan data berpasangan. Model ini menggunakan dua jaringan utama, yaitu *Generator* berbasis U-Net untuk mempertahankan detail spasial melalui *skip connections* dan *Discriminator* berbasis PatchGAN untuk mengevaluasi realisme citra pada level lokal. *Loss function* yang digunakan merupakan kombinasi antara *adversarial loss* dan *L1 loss* guna menjaga keseimbangan antara realisme visual dan kesesuaian struktur citra. Pelatihan dilakukan selama 100 epoch dengan *batch size* 32 menggunakan optimizer Adam (learning rate 0,0002; $\beta_1 = 0,5$), dengan rasio pembaruan *Generator* dan *Discriminator* disesuaikan dari 1:1 hingga 1:3 untuk menjaga stabilitas dan menghindari *mode collapse*.

Evaluasi

Evaluasi kinerja model dilakukan dengan menggunakan dua metrik utama, yaitu

Structural Similarity Index Measure (SSIM) dan *Peak Signal-to-Noise Ratio (PSNR)*. SSIM digunakan untuk menilai kesamaan struktur antara citra hasil restorasi dengan citra asli, sehingga dapat menggambarkan seberapa baik model dalam mempertahankan detail spasial dan tekstur. Sementara itu, PSNR digunakan untuk mengukur kualitas visual citra berdasarkan perbandingan antara tingkat sinyal dan noise. Semakin tinggi nilai PSNR, semakin baik kualitas citra yang dihasilkan karena lebih sedikit distorsi yang muncul. Kombinasi kedua metrik ini memberikan gambaran yang komprehensif mengenai kemampuan model dalam menghasilkan citra hasil restorasi yang tidak hanya mirip secara visual, tetapi juga akurat secara struktural terhadap citra asli.

Deployment Model




Model yang telah dilatih kemudian diimplementasikan ke dalam bentuk aplikasi berbasis web. Aplikasi ini memungkinkan pengguna mengunggah citra rusak, melakukan proses restorasi secara otomatis menggunakan model Pix2Pix GAN, serta mengunduh citra yang telah direstorasi. Implementasi berbasis web dipilih agar sistem dapat diakses dengan mudah tanpa memerlukan instalasi perangkat lunak tambahan.

HASIL DAN PEMBAHASAN

Hasil Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah CelebA-HQ dengan resolusi 256×256 pixel. Dataset ini dipilih karena memiliki variasi ekspresi wajah, usia, gender, sudut pengambilan gambar, dan pencahayaan, sehingga mewakili kondisi nyata yang kompleks. Dataset kemudian dimodifikasi ke dalam tiga tingkat kerusakan yang dapat dilihat pada Tabel 1 berikut:

Tabel 1 Dataset tipe citra rusak

Gambar	Deskripsi
 <p>Tipe 1 : Ringan/Mudah</p>	Ringan (Tipe 1) – ditandai dengan noise halus atau coretan pada area non-esensial seperti rambut atau latar belakang.
 <p>Tipe 2 : Sedang</p>	Sedang (Tipe 2) – kerusakan melibatkan sebagian wajah, misalnya pada pipi atau dahi, tetapi tidak mengenai organ vital seperti mata atau hidung.
 <p>Tipe 3 : Berat/Sulit</p>	Berat (Tipe 3) – kerusakan parah yang menutupi area vital, misalnya hidung, mulut, atau mata.

Klasifikasi ini penting untuk menguji sejauh mana model mampu menangani

variasi tingkat kerusakan. Pada kerusakan ringan, informasi wajah masih relatif utuh, sementara pada kerusakan berat model harus melakukan rekonstruksi fitur wajah yang hilang secara signifikan.

Data Preprocessing



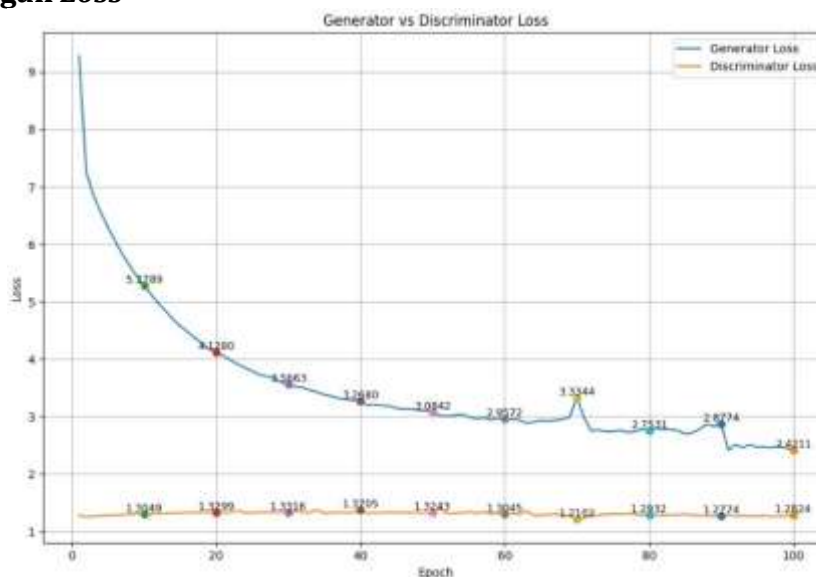
Gambar 3 Hasil Citra *Preprocessing*

Seluruh dataset diproses melalui tahap preprocessing sebelum masuk ke model:

- Pengurutan alfanumerik memastikan kesesuaian pasangan citra rusak dan citra asli.
- Konversi format warna dilakukan dari BGR ke RGB agar konsisten dengan pustaka deep learning.
- Normalisasi nilai *pixel* ke rentang $[-1,1]$ mempercepat konvergensi dan menjaga kestabilan pelatihan.
- Validasi data memastikan tidak ada pasangan citra yang hilang atau *corrupt*.

Visualisasi hasil preprocessing pada Gambar 3 menunjukkan bahwa meskipun sebagian besar citra mengalami degradasi visual, struktur wajah masih dapat dikenali dengan jelas. Hal ini menjadi indikator bahwa dataset cukup representatif untuk melatih model GAN.

Hasil Pelatihan Model Perbandingan *Loss*



Gambar 4 *Genertaor Loss vs Discriminator Loss*

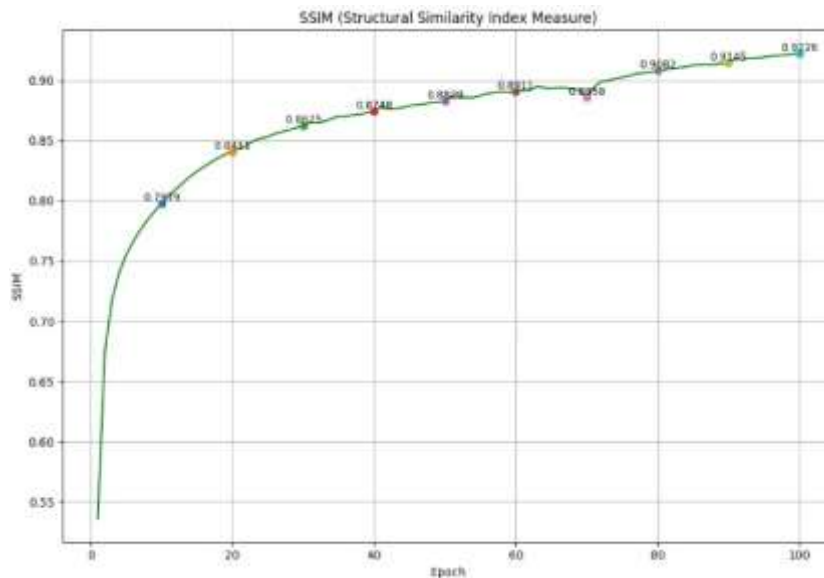
Proses pelatihan dilakukan selama 100 epoch menggunakan optimizer Adam dengan learning rate 0,0002 dan parameter $\beta_1 = 0,5$. Strategi pelatihan diatur

dalam tiga fase rasio pembaruan *Generator-Discriminator* (1:1 -> 2:1 -> 3:1). Penyesuaian rasio ini terbukti efektif menjaga stabilitas dan mengurangi risiko *mode collapse*.

Hasil *loss curve* pada Gambar 4 memperlihatkan bahwa *Generator Loss* menurun konsisten hingga akhir pelatihan, menandakan kemampuan model dalam menghasilkan citra yang semakin mirip dengan citra asli. Sementara itu, *Discriminator Loss* berfluktuasi sesuai dinamika adversarial, namun tetap dalam rentang yang stabil.

Hasil Evaluasi

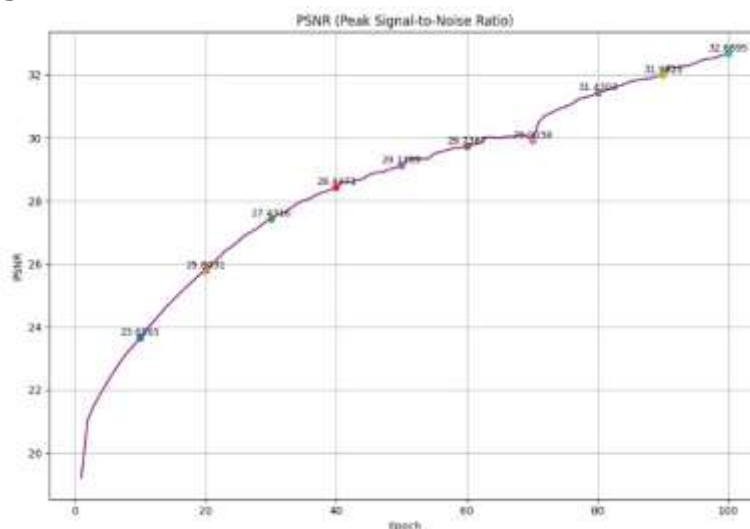
- Evaluasi SSIM



Gambar 5 Evaluasi SSIM

SSIM meningkat dari 0,7979 pada epoch ke-10 menjadi 0,9226 pada epoch ke-100 yang dapat dilihat pada Gambar 5. Nilai di atas 0,9 menunjukkan model berhasil mempertahankan detail spasial dan struktur citra wajah.

- Evaluasi PSNR



Gambar 6 Evaluasi PSNR

PSNR meningkat dari 23,65 dB pada awal pelatihan menjadi 32,68 dB pada akhir pelatihan yang dapat dilihat pada Gambar 6. Nilai ini menunjukkan penurunan distorsi visual dan noise yang signifikan. Hasil ini menegaskan efektivitas arsitektur Pix2Pix dalam mengatasi kerusakan citra digital. Jika dibandingkan dengan penelitian sebelumnya yang hanya mencapai PSNR sekitar 21,73 dB [13], pencapaian penelitian ini jauh lebih baik, terutama karena adanya strategi penyesuaian rasio pembaruan *Generator-Discriminator*.

Hasil *Deployment* Model



Gambar 7 Hasil Restorasi citra tipe 1

Model berhasil merekonstruksi citra dengan akurasi tinggi (~95%) yang dapat dilihat pada Gambar 7. Area yang rusak dapat dipulihkan secara mulus sehingga hasil tampak natural. Misalnya, goresan kecil pada rambut berhasil dihilangkan tanpa meninggalkan artefak berarti.



Gambar 8 Hasil Restorasi citra tipe 2

Pada Gambar 8 restorasi berhasil dengan tingkat akurasi ~93%. Meskipun kerusakan sudah memasuki area wajah, model mampu menjaga konsistensi tekstur kulit dan kontur wajah. Beberapa distorsi kecil masih terlihat di area tepi, tetapi tidak mengurangi kualitas visual secara signifikan.



Gambar 9 Hasil Restorasi citra tipe 3

Pada Gambar 9 kasus ini, model menghadapi tantangan terbesar karena harus merekonstruksi area vital wajah. Tingkat keberhasilan berkisar 85–90%. Model cukup baik dalam mengisi bagian hidung yang hilang, meskipun detail halus seperti bentuk bibir atau tekstur rambut masih belum sempurna.

Temuan ini memperlihatkan bahwa semakin besar area citra yang rusak, semakin berkurang kemampuan GAN dalam melakukan restorasi secara optimal [14]. Namun, dibandingkan metode konvensional seperti interpolasi bilinear, pendekatan GAN jauh lebih unggul karena mampu menghasilkan rekonstruksi yang realistis.

KESIMPULAN

Penelitian ini berhasil merancang sistem restorasi citra digital berbasis Pix2Pix *Generative Adversarial Network*s (GAN) dengan dataset CelebA-HQ yang telah dimodifikasi pada tiga tingkat kerusakan, di mana model mencapai performa tinggi dengan nilai SSIM 0,9226 dan PSNR 32,68 dB. Hasil menunjukkan bahwa sistem mampu merekonstruksi citra dengan baik pada kerusakan ringan dan sedang dengan akurasi di atas 90%, serta tetap memberikan hasil yang layak pada kerusakan berat meskipun detail halus belum sepenuhnya sempurna. Dibandingkan metode konvensional, pendekatan GAN terbukti lebih efektif dalam menghasilkan citra yang realistis dan natural, serta implementasi berbasis web yang dikembangkan memudahkan pengguna untuk melakukan proses unggah, restorasi, dan unduh citra, sehingga seluruh tujuan penelitian dapat tercapai dan berpotensi untuk dikembangkan lebih lanjut pada domain citra lain maupun dengan arsitektur GAN yang lebih mutakhir.

DAFTAR PUSTAKA

- [1] L. Galteri, L. Seidenari, M. Bertini, and A. Del Bimbo, "Deep Universal Generative Adversarial Compression Artifact Removal," *IEEE Trans. Multimed.*, vol. 21, no. 8, pp. 2131–2145, 2019, doi: 10.1109/TMM.2019.2895280.
- [2] K. Zhang, W. Zuo, L. Zhang, and D. Computing, "Deep plug-and-play super-resolution for arbitrary blur kernels," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2019-June, pp. 1671–1681, 2019, doi: 10.1109/CVPR.2019.00177.
- [3] S. Karavarsamis, I. Gkika, V. Gkitsas, K. Konstantoudakis, and D. Zarpalas, "A Survey of Deep Learning-Based Image Restoration Methods for Enhancing Situational Awareness at Disaster Sites: The Cases of Rain, Snow and Haze," *Sensors*, vol. 22, no. 13, 2022, doi: 10.3390/s22134707.
- [4] M. Triningssi, T. Ama, A. R. Himamunanto, C. Setyawan, P. S. Informatika, and U. K. Immanuel, "Peningkatan Resolusi Citra dengan Menggunakan Metode GAN untuk Aplikasi Peningkatan Gambar," vol. 5, no. 3, pp. 1287–1296, 2024.
- [5] S. Gotamaa and I. W. S. Santiyasaa, "Image Restoration Menggunakan Metode Lucy-Richardson Pada Citra Underwater," *Resolusi Rekayasa Tek. Inform. dan Inf.*, vol. 1, no. 3, pp. 179–187, 2021, [Online]. Available: <https://djournals.com/resolusi/article/view/128>
- [6] M. Cao, H. Feng, H. Xiao, S. Computer, and S. Information Technology, "An Improved GAN-Based Image Restoration Method for Imaging Logging Images," *Appl. Sci.*, vol. 13, no. 16, 2023, doi: 10.3390/app13169249.
- [7] I. Goodfellow *et al.*, "Generative Adversarial Networkss," *Commun. ACM*, vol. 63, no. 11, pp. 139–144, 2020, doi: 10.1145/3422622.
- [8] M. Maharani and T. A. Salim, "Strategi Pemerintah menggunakan AI : Studi Kasus

- Restorasi Warisan Budaya (Koleksi Foto Prajurit) untuk Peringatan 70 Tahun Gencatan Senjata Korea Selatan Government Strategies Using AI : A Case Study of Cultural Heritage Restoration (Soldier Photo Col,” vol. 15, no. 2, pp. 117–130, 2024.
- [9] D. Caruso *et al.*, “Low-dose liver CT: image quality and diagnostic accuracy of deep learning image reconstruction algorithm,” *Eur. Radiol.*, vol. 34, no. 4, pp. 2384–2393, 2024, doi: 10.1007/s00330-023-10171-8.
- [10] P. Salehi and A. Chalechale, “Pix2Pix-based Stain-to-Stain Translation: A Solution for Robust Stain Normalization in Histopathology Images Analysis,” *Iran. Conf. Mach. Vis. Image Process. MVIP*, vol. 2020-Febru, 2020, doi: 10.1109/MVIP49855.2020.9116895.
- [11] W. Weng and X. Zhu, “INet: Convolutional Networks for Biomedical Image Segmentation,” *IEEE Access*, vol. 9, pp. 16591–16603, 2021, doi: 10.1109/ACCESS.2021.3053408.
- [12] V. Kushwaha, P. Shukla, and G. C. Nandi, “Generating quality grasp rectangle using Pix2Pix GAN for intelligent robot grasping,” *Mach. Vis. Appl.*, vol. 34, no. 1, 2023, doi: 10.1007/s00138-022-01362-2.
- [13] M. Liu, X. Su, X. Yao, W. Hao, and W. Zhu, “Lensless Image Restoration Based on Multi-Stage Deep Neural Networks and Pix2pix Architecture,” *Photonics*, vol. 10, no. 11, 2023, doi: 10.3390/photonics10111274.
- [14] Y. He, D. Zhao, Z. Ren, H. Qin, and P. Jiang, “基于改进 pix2pix 框架的人脸图像修复模型,” 2024.
- [15] A. Sriram, A. Vatsa, A. Kumar, S. Vats, and A. Kumar, “Challenges and Opportunities in Malignant Image Reconstruction Using GAN: A Review,” *2024 IEEE Integr. STEM Educ. Conf. ISEC 2024*, no. March, 2024, doi: 10.1109/ISEC61299.2024.10664911.
- [16] H. Hoyez, C. Schockaert, J. Rambach, B. Mirbach, and D. Stricker, “Unsupervised Image-to-Image Translation : A Review,” pp. 1–27, 2022.
- [17] M. Trigka and E. Dritsas, “A Comprehensive Survey of Deep Learning Approaches in Image Processing,” *Sensors*, vol. 25, no. 2, 2025, doi: 10.3390/s25020531.
- [18] A. Maulana, C. Fatichah, N. Suciati, D. Teknik Informatika, and N. Surabaya, “Facial Inpainting Pada Citra Wajah Unaligned Menggunakan *Generative Adversarial Networks* Dengan Feature Reconstruction Loss,” *JUTI J. Ilm. Teknol. Inf.*, vol. 18, no. 2, pp. 171–178, 2020.
- [19] X. Wang, L. Sun, A. Chehri, and Y. Song, “A Review of GAN-Based Super-Resolution Reconstruction for Optical Remote Sensing Images,” *Remote Sens.*, vol. 15, no. 20, pp. 1–34, 2023, doi: 10.3390/rs15205062.
- [20] K. Liu, J. Li, and S. S. Hussain Bukhari, “Overview of Image Inpainting and Forensic Technology,” *Secur. Commun. Networks*, vol. 2022, 2022, doi: 10.1155/2022/9291971.