

Optimasi Rekonstruksi Dan Pengenalan Wajah Berbasis Generative Adversarial Network (GAN) Dan CNN

Salamun¹, Stephen Scorpionus Ryanto², Ira Puspita Sari³

^{1,2,3}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Abdurrah

e-mail: *¹salamun@univrab.ac.id, ²stephen.scorpionus20@student.univrab.ac.id, ³ira.puspita.sari@univrab.ac.id

Abstract - Generative Adversarial Network (GAN) is a versatile deep learning-based algorithm that is increasingly being used in the modern era, especially in the field of image processing. One of the main functions of GAN is to reconstruct facial images by utilizing data extracted from a dataset. In this process, the GAN generator model generates high-quality synthetic images designed to deceive the discriminator model. In this study, the GAN algorithm was used for the reconstruction of face images based on the Human Faces dataset. The images from this reconstruction were then further analyzed using the Convolutional Neural Network (CNN) algorithm for the facial recognition process. This study aims to: (1) develop a GAN-based facial reconstruction model, (2) evaluate the performance of the GAN algorithm in generating synthetic images, and (3) implement CNN to recognize the reconstructed facial images. Evaluation of the results of GAN reconstruction was carried out using performance metrics such as Structural Similarity Index (SSIM), Peak Signal-to-Noise Ratio (PSNR), and Mean Squared Error (MSE). The evaluation results show that the GAN model produces promising performance with an average Generator Loss of 0.392516, Discriminator Loss of 1.389985, Generator L1 Loss of 0.0005, and Generator Total Loss of 6.949564. In addition, the reconstruction results are considered to be of high quality with a PSNR of 28.611917, SSIM 0.952875, and MSE 16.426186. On the other hand, the CNN algorithm managed to recognize the reconstructed facial images with a good degree of accuracy. With the integration of GAN for reconstruction and CNN for facial recognition, this study proves the potential of both in facial image processing, especially in applications that require high-quality results and reliable identification capabilities. These results could be the basis for the development of future reconstruction and facial recognition technologies.

Keyword : Generative Adversarial Network (GAN), Reconstruction, Convolutional Neural Network (CNN)

Abstrak - Generative Adversarial Network (GAN) adalah algoritma berbasis deep learning yang serbaguna dan semakin banyak digunakan di era modern, khususnya dalam bidang pengolahan citra. Salah satu fungsi utama GAN adalah melakukan rekonstruksi gambar wajah dengan memanfaatkan fitur data yang diekstrak dari sebuah dataset. Dalam proses ini, model generator GAN menghasilkan gambar sintetik berkualitas tinggi yang dirancang untuk menipu model discriminator. Dalam penelitian ini, algoritma GAN digunakan untuk rekonstruksi gambar wajah berdasarkan dataset Human Faces. Gambar hasil rekonstruksi ini kemudian dianalisis lebih lanjut menggunakan algoritma Convolutional Neural Network (CNN) untuk proses pengenalan wajah. Penelitian ini bertujuan untuk: (1) mengembangkan model rekonstruksi wajah berbasis GAN, (2) mengevaluasi kinerja algoritma GAN dalam menghasilkan gambar sintetik, dan (3) mengimplementasikan CNN untuk mengenali gambar wajah hasil rekonstruksi. Evaluasi terhadap hasil rekonstruksi GAN dilakukan dengan menggunakan metrik performa seperti Structural Similarity Index (SSIM), Peak Signal-to-Noise Ratio (PSNR), dan Mean Squared Error (MSE). Hasil evaluasi menunjukkan bahwa model GAN menghasilkan performa yang menjanjikan dengan rata-rata Generator Loss sebesar 0.392516, Discriminator Loss 1.389985, Generator L1 Loss 0.0005, dan Generator Total Loss 6.949564. Selain itu, hasil rekonstruksi dinilai memiliki kualitas tinggi dengan PSNR sebesar 28.611917, SSIM 0.952875, dan MSE 16.426186. Di sisi lain, algoritma CNN berhasil mengenali gambar wajah hasil rekonstruksi dengan tingkat akurasi yang baik. Dengan integrasi GAN untuk rekonstruksi dan CNN untuk pengenalan wajah, penelitian ini membuktikan potensi keduanya dalam pengolahan citra wajah, terutama pada aplikasi yang membutuhkan hasil berkualitas tinggi dan kemampuan identifikasi yang andal. Hasil ini dapat menjadi dasar untuk pengembangan teknologi rekonstruksi dan pengenalan wajah di masa depan.

Kata Kunci : Generative Adversarial Network (GAN), Rekonstruksi, Convolutional Neural Network (CNN)

I. PENDAHULUAN

Teknologi telah berkembang pesat di seluruh dunia dalam berbagai sektor. Salah satunya, teknologi mendukung kemajuan riset, termasuk dengan adanya kecerdasan buatan (AI) yang dapat mempelajari data sampel untuk menghasilkan output yang lebih baik[1]. Salah satu bidang yang berkembang seiring kemajuan teknologi adalah pemrosesan citra (image processing), yang mencakup teknik pengolahan gambar dengan komputer untuk meningkatkan kualitas gambar. Pemrosesan citra meliputi beberapa subdivisi, seperti rekonstruksi wajah (face reconstruction) dan pengenalan wajah (face recognition). Rekonstruksi wajah bekerja dengan membangun fitur visual gambar seseorang dan melatih dataset yang diberikan, sedangkan pengenalan wajah menggunakan titik fitur visual untuk membandingkan gambar berdasarkan fitur tersebut[2]. Salah satu jenis algoritma yang digunakan dalam bidang image processing adalah generative adversarial network (GAN) yang merupakan bentuk algoritma deep learning dengan menggunakan dua komponen yang bersaing secara paralel untuk menghasilkan output akhir berkualitas tinggi. [3]Algoritma GAN memiliki banyak fungsi dan kegunaan, salah satunya menghasilkan atau mensintesis gambar dari teks maupun gambar lain yang terkandung dalam suatu dataset dengan mempelajari distribusi pada dataset untuk menciptakan maupun melakukan rekonstruksi gambar baru dengan menghilangkan occlusion pada gambar. Namun, algoritma ini juga memiliki beberapa hambatan seperti penggunaan daya komputasi yang cukup tinggi, resiko terjadinya overfit atau non-diversitas pada data, serta penggunaan dataset berskala kecil. [4]

Urgensi penelitian ini terletak pada pentingnya pengembangan teknologi rekonstruksi wajah yang lebih akurat dan efisien dalam berbagai kondisi, seperti pada gambar wajah yang tidak lengkap atau terhalang. Penelitian ini bertujuan untuk mengeksplorasi potensi GAN dalam meningkatkan kualitas rekonstruksi wajah, mengintegrasikannya dengan teknologi pengenalan wajah, serta mencari solusi atas tantangan seperti kebutuhan komputasi tinggi dan keterbatasan dataset. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi signifikan pada pengembangan teknologi pengenalan wajah yang dapat diaplikasikan pada berbagai situasi, termasuk keamanan dan forensik[5][6]. potensi penggunaan GAN dalam meningkatkan kualitas rekonstruksi wajah, serta mengintegrasikan teknologi pengenalan wajah untuk mendukung akurasi identifikasi wajah dalam berbagai kondisi, termasuk wajah yang terhalang atau tidak lengkap[7] [8]. Selain itu, penelitian ini juga akan mengidentifikasi tantangan yang dihadapi dalam penerapan GAN, seperti isu terkait komputasi yang intensif dan keterbatasan dataset, serta mencari solusi untuk mengatasi masalah tersebut, seperti dengan menggunakan dataset yang lebih besar dan teknik regularisasi yang lebih efektif[9] [10] [11]. Kebaruan dalam penelitian ini terletak pada penerapan kombinasi GAN untuk rekonstruksi wajah dan CNN untuk pengenalan gambar hasil rekonstruksi. Berbeda dengan penelitian sebelumnya, penelitian ini menggunakan dataset yang lebih besar (7.290 gambar kotor, 5.200 gambar bersih) dengan resolusi lebih tinggi (256x256 piksel). Selain itu, proses pelatihan dilakukan dengan intensitas lebih tinggi (500 epoch, 250 langkah per epoch), didukung oleh arsitektur yang lebih kompleks dengan fungsi checkpoint serta evaluasi metrik secara paralel. Dengan pendekatan ini, penelitian ini diharapkan dapat mengatasi tantangan seperti overfitting dan keterbatasan dataset, serta meningkatkan efisiensi dan akurasi algoritma GAN dalam rekonstruksi wajah. Kombinasi dengan CNN memungkinkan evaluasi yang lebih terukur untuk pengenalan wajah, sehingga memperluas aplikasi teknologi ini dalam berbagai kondisi, termasuk gambar wajah yang terhalang atau tidak lengkap[13][14].

II. PENELITIAN YANG TERKAIT

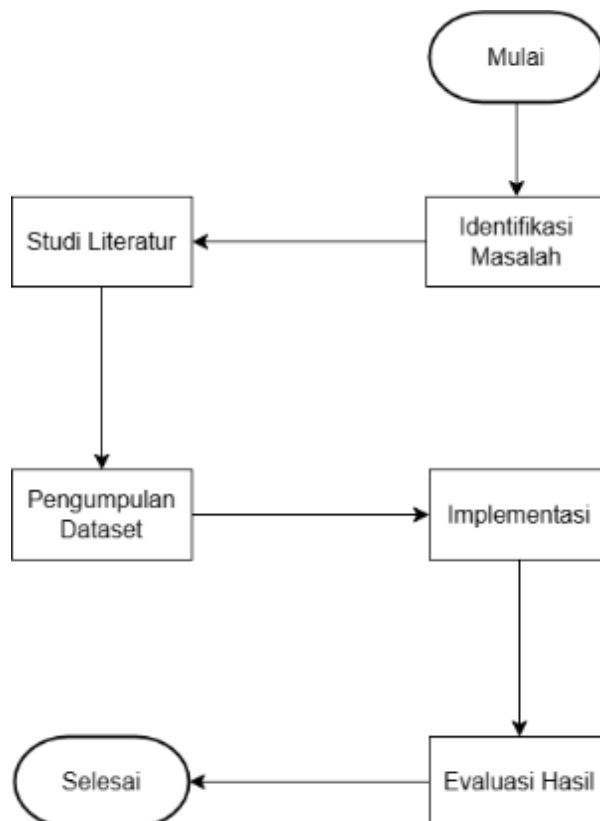
Penelitian terkait pertama dengan judul *“Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions”*[15]. Pada penelitian ini, dibahas mengenai konsep penggunaan algoritma convolutional neural network (CNN) dalam bidang image processing, arsitektur yang mencakup seluruh alur kerja CNN, aplikasi serta fungsinya seperti pada pengenalan dan klasifikasi gambar, serta potensi perkembangan yang dapat dilakukan pada algoritma CNN saat ini dengan tujuan untuk menjabarkan mengenai celah pada penelitian CNN dan menjabarkan CNN secara detail. Hasil dari penelitian ini adalah penjabaran deskriptif seputar algoritma CNN serta bagaimana parameter pada algoritma dapat mempengaruhi kualitas kinerja dari algoritma serta menyimpulkan bahwa bagian paling penting dari CNN adalah convolution layer. Penelitian terkait yang kedua dengan judul *“Image Super-Resolution and Deblurring Using Generative Adversarial Network”*[5]. Penelitian ini membahas mengenai rekonstruksi gambar asli yang memiliki resolusi rendah menjadi gambar yang jelas menggunakan penggabungan novel *image super-resolution* dan *non-uniform motion deblurring* berbasis algoritma

Generative Adversarial Network (GAN) untuk menyelesaikan masalah input gambar resolusi rendah dan memiliki blur kompleks[12].

Hasil dari penelitian ini adalah suatu model GAN eksperimental yang memiliki parameter kualitas yang lebih tinggi dibandingkan model-model GAN yang diuji sebelumnya dengan kenaikan sebesar 0.033. Berdasarkan penelitian serupa yang dilakukan, terdapat perbedaan serta novelty atau pengembangan yang dilakukan pada penelitian ini, yaitu penggunaan dataset dalam jumlah lebih besar (data kotor 7290 gambar, data bersih ~5200 gambar), resolusi lebih tinggi (dimensi 256 x 256 pixel), proses training yang lebih intensif (500 epoch dengan 250 step per epoch), serta arsitektur keseluruhan yang mengalami perkembangan seperti adanya fungsi checkpoint dan mengambil nilai loss dan parameter metric secara parallel berjalannya proses training dan/atau testing. Kemudian, penelitian ini menggunakan algoritma CNN untuk mengevaluasi dan melakukan pengenalan terhadap gambar hasil rekonstruksi GAN[13] [14].

III. METODE PENELITIAN

Dataset yang digunakan dalam penelitian ini bersifat dataset collecting yang didapatkan dari database CelebA yang mengandung berbagai gambar wajah yang memiliki occlusion dalam bentuk objek pada wajah seperti masker. Data yang telah dikumpulkan kemudian melalui preprocessing untuk menyesuaikan gambar untuk selanjutnya, seperti melakukan resize dan downscaling pada gambar. Kerangka kerja yang digunakan dalam penelitian ini dapat dilihat pada diagram alir berikut:



Gbr 1. Kerangka Kerja Penelitian

1. Identifikasi Masalah: masalah yang melatarbelakangi penelitian akan diteliti dan menjadi tujuan penelitian dilakukan, dimana dalam penelitian ini masalah utama adalah penerapan algoritma GAN untuk teknik rekonstruksi dan pengenalan wajah.
2. Studi Literatur: literatur yang berkaitan dengan penelitian yang sedang dilakukan akan dijadikan referensi sebagai poin yang dapat dikembangkan atau dijadikan panduan dalam melakukan penelitian dengan merujuk jurnal atau artikel dalam kurun 5 tahun.
3. Pengumpulan Data: data yang digunakan dalam penelitian akan dikumpulkan, berupa data gambar wajah

yang memiliki *occlusion* dalam bentuk masker. Data tersebut kemudian melalui *preprocessing* dan *preprocessing* akan gambar seperti proses *resize* dan *downscaling*.

4. Implementasi: model algoritma GAN yang digunakan dalam proses rekonstruksi wajah akan dirancang.
5. Evaluasi Hasil: output yang dihasilkan dari model algoritma GAN akan dievaluasi melalui *parameter metric* SSIM dan PSNR.

IV. HASIL DAN PEMBAHASAN

Pada tahap ini, masalah yang melatarbelakangi penelitian yang akan dilakukan berupa kekurangan algoritma GAN dalam menghasilkan gambar output berkualitas tinggi dengan menggunakan sampel dataset berskala kecil dengan objek penelitian berupa gambar wajah output algoritma GAN. Oleh karena itu, diterapkan algoritma GAN untuk teknik rekonstruksi wajah dengan dataset skala lebih besar dimana kemudian gambar output yang dihasilkan akan diproses dengan teknik pengenalan wajah. Dalam proses pengerjaan penelitian, dilakukan studi literatur yang menghasilkan pengertian dan landasan teori yang berhubungan dengan penelitian. Hasil dari studi literatur berupa informasi terkait dengan teknik rekonstruksi dan pengenalan wajah berbasis GAN, dan hasil studi literatur ini digunakan sebagai landasan atau fondasi dalam melakukan penelitian, Dataset yang digunakan dalam penelitian ini

berupa dataset *Human Faces* oleh Ashwin Gupta yang diambil melalui situs Kaggle. Dataset ini mengandung gambar wajah dari berbagai jenis kategori yang dapat digunakan dalam penelitian *image processing* sebanyak 7219 gambar. Dataset *Human Faces* yang digunakan dalam penelitian terlebih dahulu melalui *preprocessing* yang meliputi proses *resize* (perubahan ukuran gambar) dan menambahkan *occlusion* sintetik berupa masker.



Gbr 2. Dataset *Human Faces*

Pada gambar 2, terlihat dataset *Human Faces* yang telah melalui *preprocessing*, disesuaikan dengan dimensi 256 x 256 pixel. Tujuan dari *preprocessing* ini adalah memudahkan algoritma GAN dalam mengolah gambar untuk menghasilkan output yang berkualitas tanpa terjadinya *overfit* atau penggunaan dataset yang tidak seragam. Setelah *preprocessing*, diterapkan algoritma GAN yang terdiri dari model *generator* dan *discriminator*. Arsitektur GAN yang diterapkan memiliki jaringan *U-Net* untuk memudahkan penyimpanan kualitas informasi fitur gambar ketika melalui lapisan-lapisan *generator* dan *discriminator*. Melalui algoritma GAN ini diambil *parameter metric* untuk mengevaluasi algoritma GAN yaitu SSIM, PSNR, *generator loss*, dan *discriminator loss*.

Gbr 3. Proses *Training* GAN

Pada gambar 3, terlihat proses *training* GAN yang terdiri dari gambar yang memiliki *occlusion* masker (kiri), gambar *real* (tengah), dan gambar hasil rekonstruksi (kanan). Proses *training* GAN dilakukan sebanyak 500 *epoch* dengan *batch size* 64. Pada tiap *epoch* juga dikumpulkan informasi berupa *parameter metric* yang akan digunakan untuk evaluasi algoritma GAN serta waktu per *epoch*.

Gbr 4. Proses *Testing* GAN

Pada gambar 4, terlihat proses *testing* GAN setelah selesainya proses *training*. Proses *testing* menggunakan 30% dari dataset *Human Faces* yang dipisah pada tahap *preprocessing* untuk mengevaluasi kemampuan rekonstruksi algoritma GAN pada data tidak dikenal.

TABEL I
PERFORMANCE METRIC TRAINING GAN

No.	<i>Performance Metric</i>	<i>Mean</i>
1	<i>Generator Loss</i>	0.392516
2	<i>Discriminator Loss</i>	1.389985
3	<i>Generator L1 Loss</i>	0.0005
4	<i>Generator Total Loss</i>	6.949564
5	<i>PSNR</i>	28.611917
6	<i>SSIM</i>	0.952875
7	<i>MSE</i>	16.426186

Pada tabel 1, tabel ini menunjukkan bahwa model GAN telah menunjukkan performa yang baik, dengan generator mampu menghasilkan gambar yang berkualitas tinggi (dibuktikan oleh nilai SSIM, PSNR, dan MSE). Meskipun generator masih memiliki total loss yang relatif tinggi, hasilnya cukup menjanjikan dalam hal realisme dan kesesuaian dengan data target.

1. Generator Loss (0.392516)

Metrik ini menunjukkan seberapa baik generator menghasilkan gambar yang mampu menipu diskriminator. Nilai yang lebih rendah menunjukkan bahwa generator semakin baik dalam menciptakan data yang menyerupai data asli. Nilai rata-rata 0.392516 menunjukkan bahwa generator cukup berhasil dalam menghasilkan gambar realistis selama pelatihan.

2. Discriminator Loss (1.389985)

Metrik ini mengukur seberapa baik diskriminator dalam membedakan antara data asli dan data yang dihasilkan oleh generator. Nilai rata-rata 1.389985 menunjukkan bahwa diskriminator mengalami kesulitan dalam membedakan data asli dari yang dihasilkan, yang bisa berarti generator telah menjadi cukup kompeten.

3. Generator L1 Loss (0.0005)

L1 Loss (Mean Absolute Error) mengukur perbedaan rata-rata absolut antara piksel gambar hasil generator dan target aslinya. Biasanya digunakan untuk memastikan gambar yang dihasilkan memiliki struktur yang serupa dengan target. Nilai 0.0005 sangat kecil, menunjukkan bahwa generator berhasil menciptakan gambar yang sangat mendekati data target dalam hal struktur atau nilai piksel.

4. Generator Total Loss (6.949564)

Total Loss mencakup semua komponen loss yang digunakan dalam pelatihan generator, seperti adversarial loss, L1 loss, atau komponen tambahan lainnya. Nilai ini relatif tinggi, kemungkinan karena komponen tambahan dalam loss yang digunakan selama pelatihan. Generator masih dalam proses menyempurnakan hasilnya.

5. PSNR (Peak Signal-to-Noise Ratio) (28.611917)

PSNR adalah metrik kuantitatif yang mengukur kualitas rekonstruksi gambar berdasarkan tingkat distorsi atau kesalahan. Nilai lebih tinggi menunjukkan kualitas gambar yang lebih baik. Nilai 28.611917 menunjukkan kualitas gambar yang dihasilkan cukup tinggi, dengan sedikit noise atau distorsi.

6. SSIM (Structural Similarity Index) (0.952875)

SSIM mengukur kesamaan struktural antara gambar hasil generator dan gambar asli. Nilai berkisar antara 0 hingga 1, di mana 1 menunjukkan kesamaan sempurna. Nilai 0.952875 sangat mendekati 1, menunjukkan gambar hasil generator memiliki kesamaan struktur yang sangat tinggi dengan gambar target asli.

7. MSE (Mean Squared Error) (16.426186)

MSE menghitung rata-rata kesalahan kuadrat antara nilai piksel gambar hasil generator dan gambar asli. Nilai lebih rendah menunjukkan kesalahan yang lebih kecil. Nilai 16.426186 menunjukkan bahwa meskipun ada sedikit perbedaan dalam nilai piksel, gambar yang dihasilkan tetap berkualitas baik.

Pada tabel 2, hasil pengujian menunjukkan bahwa model GAN memiliki kemampuan rekonstruksi wajah yang sangat baik. SSIM dan PSNR yang tinggi, disertai dengan MSE yang rendah, menunjukkan bahwa model tidak hanya menghasilkan gambar yang mendekati secara visual tetapi juga berkualitas secara kuantitatif. Selain itu, kombinasi loss yang seimbang menunjukkan pelatihan yang stabil antara generator dan discriminator.

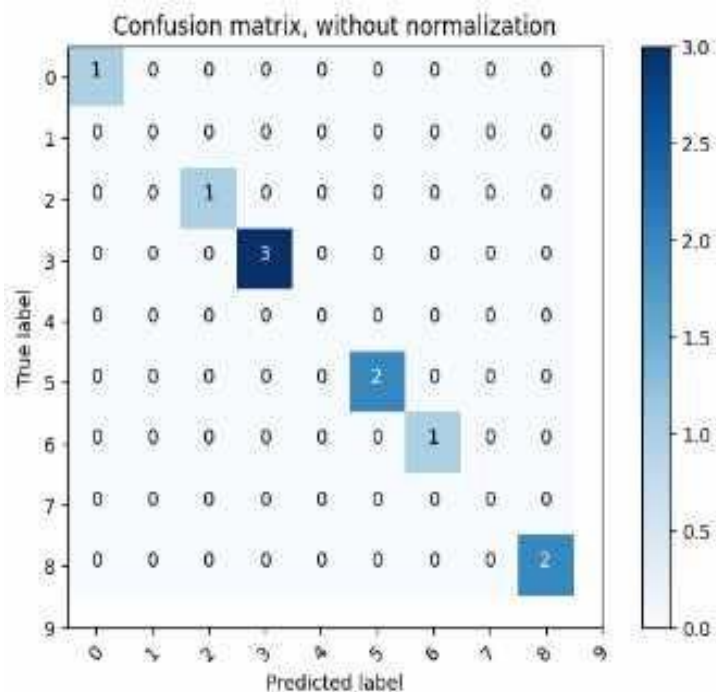
TABEL II
PERFORMANCE METRIC TESTING GAN

No.	Performance Metric	Mean
1	Generator Loss	0.6926
2	Discriminator Loss	1.3900
3	Generator L1 Loss	7.0349
4	Generator Total Loss	0.0107
5	PSNR	33.7942
6	SSIM	0.9743
7	MSE	11.4313

1. Generator Loss: Mengukur kerugian yang dialami generator selama pelatihan. Nilai rendah menunjukkan bahwa generator semakin baik dalam menghasilkan data realistis.
2. Discriminator Loss: Mengukur kerugian discriminator dalam membedakan data asli dan sintetis. Nilai tinggi mengindikasikan bahwa generator berhasil "menipu" discriminator.
3. Generator L1 Loss: Berhubungan dengan kesalahan prediksi piksel; nilai lebih rendah menunjukkan hasil rekonstruksi yang mendekati data asli.

4. Generator Total Loss: Kombinasi berbagai komponen kerugian pada generator, dengan nilai rendah mencerminkan kinerja keseluruhan yang baik.
5. PSNR: Nilai rata-rata rasio sinyal terhadap noise. PSNR tinggi (33.7942) menunjukkan bahwa gambar hasil rekonstruksi memiliki kualitas tinggi.
6. SSIM: Mengukur kesamaan struktural antara gambar asli dan rekonstruksi. SSIM tinggi (0.9743) menunjukkan bahwa struktur gambar sangat mirip dengan gambar asli.
7. MSE: Kesalahan kuadrat rata-rata antara piksel gambar asli dan rekonstruksi. Nilai MSE rendah (11.4313) menunjukkan bahwa perbedaan piksel antara gambar asli dan hasil rekonstruksi kecil.

Pada tabel 2, terlihat *parameter metric* yang diukur dari proses *testing* GAN, dimana dapat disimpulkan bahwa proses *testing* GAN menghasilkan gambar output rekonstruksi yang hampir mirip dengan gambar *real*, dengan nilai SSIM yang lebih tinggi dibandingkan *training*, namun memiliki PSNR yang lebih tinggi juga yang menandakan bahwa dalam basis per pixel masih terdapat kejanggalan dalam gambar. Setelah dilakukan proses rekonstruksi, tahap implementasi dilanjutkan dengan proses pengenalan wajah berbasis GAN dengan menggunakan ketiga jenis gambar, yaitu gambar *occlusion*, gambar *real*, dan gambar hasil rekonstruksi. Pengenalan wajah dilakukan menggunakan algoritma CNN. Dataset yang digunakan dalam proses pengenalan masih berupa dataset *Human Faces* yang dikategorikan menjadi 5 kelas dengan augmentasi berbeda-beda untuk meningkatkan kualitas pengolahan data.

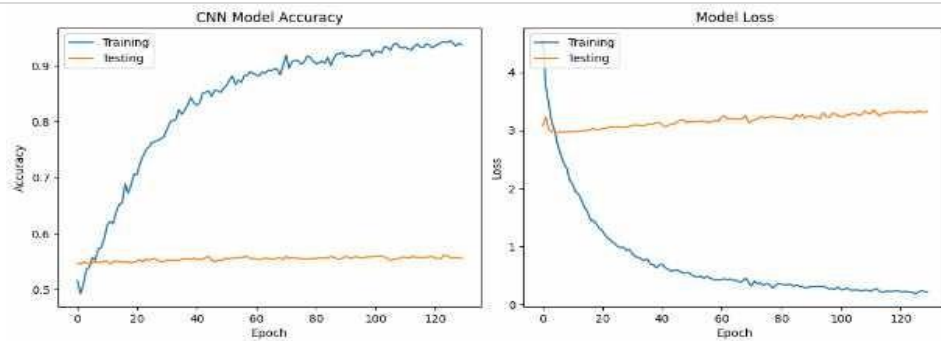


Gbr 5. *Confusion Matrix* Pengenalan Wajah

Pada gambar 5, terlihat *confusion matrix* yang didapatkan dari hasil *testing* pengenalan wajah terhadap gambar hasil rekonstruksi GAN. Kolom dalam *confusion matrix* menandakan *predicted label* atau kelas gambar menurut algoritma, dan baris menandakan *true label* atau kelas sebenarnya dari gambar.

Deskripsi tiap nilai yang berada dalam *confusion matrix* adalah sebagai berikut:

1. Pada kolom pertama, baris pertama, terdapat nilai 1 yang menandakan bahwa dari 5 kelas dalam dataset, algoritma berhasil mengenali 1 dari 5 kelas tersebut.
2. Pada kolom keempat, baris keempat, terdapat nilai 3 yang menandakan bahwa dari 5 kelas dalam dataset, algoritma berhasil mengenali 3 dari 5 kelas tersebut.
3. Pada kolom keenam, baris keenam, terdapat nilai 2 yang menandakan bahwa dari 5 kelas dalam dataset, algoritma berhasil mengenali 2 dari 5 kelas tersebut.
4. Pada kolom lainnya, terdapat nilai 0 yang menandakan bahwa algoritma tidak dapat mengenali satupun kelas gambar dari dataset.



Gbr 6. Grafik Akurasi dan *Loss* Pengenalan Wajah

Pada gambar 6, terlihat grafik yang menampilkan nilai akurasi (pada grafik kiri) dan nilai *loss* (pada grafik kanan) pada proses *training* (ditandai dengan kurva biru) dan proses *testing* (ditandai dengan kurva jingga) pengenalan wajah.



Gbr 7. Hasil Pengenalan Wajah Rekonstruksi GAN

Pada gambar 7, terlihat proses pengenalan wajah yang menghasilkan nilai 3 pada *confusion matrix*. Nilai 3 menandakan bahwa model algoritma pengenalan dapat mengenali wajah hasil rekonstruksi GAN sebanyak 3 dari 5 kelas dengan nilai akurasi 60%.

V. KESIMPULAN

Penelitian ini bertujuan untuk meningkatkan kemampuan algoritma Generative Adversarial Network (GAN) dalam merekonstruksi gambar wajah dengan kualitas tinggi, terutama ketika menggunakan dataset berskala kecil. Dengan menggunakan dataset Human Faces yang telah melalui proses preprocessing, algoritma GAN berhasil menghasilkan gambar wajah rekonstruksi yang dapat diuji lebih lanjut dengan algoritma pengenalan wajah berbasis CNN.

1. Hasil Pelatihan GAN

- **Metrik Evaluasi:** Berdasarkan tabel *Performance Metric Training GAN*, model menunjukkan kinerja yang baik dengan nilai *SSIM* 0.952875 dan *PSNR* 28.611917. Nilai ini mengindikasikan bahwa gambar hasil rekonstruksi mendekati kualitas gambar asli.
- **Kelemahan:** Nilai *Generator Total Loss* masih relatif tinggi (6.949564), mengindikasikan masih adanya ruang untuk perbaikan pada model generator.

2. Arsitektur Model:

- Penggunaan arsitektur U-Net membantu menjaga informasi fitur penting dalam proses pelatihan, sehingga menghasilkan gambar dengan detail yang lebih baik.

3. Hasil Pengujian GAN

- Pada tabel *Performance Metric Testing GAN*, terlihat peningkatan kualitas rekonstruksi dibandingkan tahap pelatihan. Hal ini ditunjukkan dengan nilai *SSIM* yang lebih tinggi (0.9743) dan *PSNR* yang meningkat menjadi 33.7942, meskipun nilai *MSE* masih ada pada angka 11.4313.
- Gambar hasil rekonstruksi dari proses testing menunjukkan kemampuan GAN untuk menghasilkan gambar yang hampir menyerupai gambar asli meskipun berasal dari data yang tidak dikenal (30% dataset).

4. Pengenalan Wajah:

- Menggunakan tiga jenis gambar (occlusion, real, dan hasil rekonstruksi), pengenalan wajah berbasis CNN menunjukkan tingkat keberhasilan akurasi sebesar 60%.
- Hasil dari *confusion matrix* menunjukkan bahwa model dapat mengenali gambar hasil rekonstruksi sebanyak 3 dari 5 kelas, namun performa ini masih memerlukan peningkatan untuk aplikasi lebih luas.

5. Grafik Akurasi dan Loss:

- Grafik menunjukkan tren peningkatan akurasi dan penurunan loss pada proses pelatihan dan pengujian, meskipun nilai akurasi testing lebih rendah dari pelatihan, menandakan tantangan dalam mengatasi *overfitting*.

Rekomendasi untuk pengembangan lebih lanjut:

1. **Peningkatan dataset:** Menggunakan dataset yang lebih besar dan beragam dapat membantu meningkatkan generalisasi model.
2. **Optimalisasi komputasi:** Mengurangi computational cost dapat dilakukan dengan strategi regularisasi yang lebih efisien.
3. **Eksperimen pada kondisi berbeda:** Menguji model pada gambar dengan tingkat *occlusion* yang lebih kompleks untuk mengevaluasi ketahanan model terhadap tantangan dunia nyata.

Penelitian ini berhasil menunjukkan bahwa penerapan algoritma GAN dengan dataset berskala besar dan preprocessing yang tepat mampu menghasilkan rekonstruksi wajah berkualitas tinggi. Proses pengenalan wajah berbasis CNN pada gambar hasil rekonstruksi menunjukkan performa yang cukup menjanjikan, meskipun masih terdapat kelemahan yang perlu diatasi, seperti tingkat akurasi yang rendah dan tingkat kesalahan prediksi yang signifikan.

DAFTAR PUSTAKA

- [1] Ahmed, A. A., Ali, W., Abdullah, T. A. A. and Malebary, S. J. 2023. *Classifying Cardiac Arrhythmia from ECG Signal Using 1D CNN Deep Learning Model*. MDPI. doi: <https://doi.org/10.3390/math11030562>
- [2] Al-Adhaileh, M. H., Verma, A., Aldhyani, T. H. H. and Koundal, D. 2023. *Potato Blight Detection Using Fine-Tuned CNN Architecture*. MDPI. doi: <https://doi.org/10.3390/math11061516>
- [3] Alqahtani, H., Kavakli-Thorne, M. and Kumar, G. 2019. *Applications of Generative Adversarial Network (GANs): An Updated Review*. *Archives of Computational Methods in Engineering*. doi: <https://doi.org/10.1007/s11831-019-09388-y>
- [4] Bakurov, I., Buzzelli, M., Castelli, M., Schettini, R. and Vanneschi, L. *Parameter Optimization of the Structural Similarity Index*. *Society for Imaging Science and Technology*. doi: <https://doi.org/10.2352/issn.2694-118X.2020.LIM-13>
- [5] Du, B., Ren, X., Chen, S., Ren, K. and Cao, D. 2019. *Image Super-Resolution and Deblurring Using Generative Adversarial Network*. *Proceedings of the 2019 8th International Conference on Computing and Pattern Recognition*. doi: <https://doi.org/10.1145/3373509.3373547>
- [6] Erakin, M.E., Demir, U. and Ekenel, H.K. 2021. *On Recognizing Occluded Faces in the Wild*. *arXiv (Cornell University)*. doi: <https://doi.org/10.48550/arXiv.2109.03672>
- [7] Gong, Y., Liu, G., Xue, Y., Li, R. and Meng, L. 2023. *A Survey on Dataset Quality in Machine Learning*. *Information and Software Technology*, 162, pp. 107268-107268. doi: <https://doi.org/10.1016/j.infsof.2023.107268>
- [8] Jalolov, T.S. 2023. *Solving Complex Problems in Python*. *American Journal of Language, Literacy and Learning in STEM Education (2993-2769)*, [Online] 1(9), pp. 481-484. Available at: <https://grmjournals.us/index.php/STEM/article/view/1584/1363>
- [9] Khaleel, M., Ahmed, A.A. and Alsharif, A. 2023. *Artificial Intelligence in Engineering*. *Brilliance: Research of Artificial Intelligence*, 3(1), pp. 32-42. doi: <https://doi.org/10.47709/brilliance.v3i1.2170>
- [10] Li, L., Mu, X., Li, S. and Peng, H. 2020. *A Review of Face Recognition Technology*. *IEEE Access*, 8, pp. 139110-139120. doi: 10.1109/ACCESS.2020.3011028
- [11] Lium, O., Yong, B.K., Antonios, D. and Theoharis, T. 2021. *Robust 3D Face Reconstruction Using One/Two Facial Images*. *Journal of Imaging* [Online] 7(9), pp. 169-169. doi: <https://doi.org/10.3390%2Fjimaging7090169>.
- [12] Lu, P., Song, B. and Xu, L. 2020. *Human Face Recognition Based on Convolutional Neural Network and Augmented Dataset*. *Systems Science & Control Engineering*, 9(sup2), pp. 29-37. doi: <https://doi.org/10.1080/21642583.2020.1836526>
- [13] Mahmoud, M.H. and Kang, H. 2023. *GANMasker: A Two-Stage Generative Adversarial Network for High-Quality Face Mask Removal*. *Sensors*, 23(16), pp. 7094-7094. doi: <https://doi.org/10.3390/s23167094>
- [14] Nestor, A., Lee, A.C.H., Plaut, D.C. and Behrmann, M. 2020. *The Face of Image Reconstruction: Progress, Pitfalls, Prospects*. *Trends in Cognitive Sciences*, 24(9), pp. 747-759. doi: <https://doi.org/10.1016/j.tics.2020.06.006>
- [15] Taye, M.M. 2023. *Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions*. *Computation*, 11(3), pp. 52-52. doi: <https://doi.org/10.3390/computation11030052>