

**Implementasi Deep Learning PIX2PIX GAN
untuk Restorasi Citra Sidik Jari sebagai Upaya Penguatan
Sistem Keamanan Biometrik dan Forensik Digital**

LAPORAN TUGAS AKHIR

Laporan ini Disusun untuk Memenuhi Salah Satu Syarat Memperoleh Gelar
Sarjana Strata 1 (S1) pada Program Studi Teknik Informatika Fakultas Teknologi
Industri Universitas Islam Sultan Agung Semarang



DISUSUN OLEH:

ANDRIANTO KUSUMO WIBOWO

NIM 32602100028

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG
SEMARANG
2025**

**IMPLEMENTATION OF PIX2PIX GAN DEEP LEARNING
FOR FINGERPRINT IMAGE RESTORATION
AS AN EFFORT TO STRENGTHEN
BIOMETRIC SECURITY SYSTEM
AND DIGITAL FORENSICS**

FINAL PROJECT

Proposed to complete the requirement to obtain a bachelor's degree (S1)
at Informatics Engineering Departement of Industrial Technology Faculty
Sultan Agung Islamic University of Semarang.



ARRANGED BY:

ANDRIANTO KUSUMO WIBOWO

NIM 32602100028

**MAJORING OF INFORMATICS ENGINEERING
INDUSTRIAL TECHNOLOGY FACULTY
SULTAN AGUNG ISLAMIC UNIVERSITY
SEMARANG**

2025

**LEMBAR PENGESAHAN
TUGAS AKHIR**

**IMPLEMENTASI DEEP LEARNING PIX2PIX GAN
UNTUK RESTORASI CITRA SIDIK JARI SEBAGAI UPAYA PENGUATAN
SISTEM KEAMANAN BIOMETRIK DAN FORENSIK DIGITAL**

**ANDRIANTO KUSUMO WIBOWO,
NIM 32602100028**

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal : 14 Agustus 2025

TIM PENGUJI UJIAN SARJANA :


Badie'ah, S.T., M.Kom
NIK.210615044
(Ketua Penguji)


.....
20-08-2025

Sam Farisa C, ST. M. Kom.
NIK. 210615044
(Anggota Penguji)


.....
21-08-2025

Ir. Sri Mulvono, M.Eng.
NIK. 210616049
(Pembimbing)


.....
25-08-2025

Semarang, 25 Agustus 2025

Mengetahui,

**Kaprodi Teknik Informatika
Universitas Islam Sultan Agung**


Moch Taufik, S.T., M.IT
NIK. 210604034

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan dibawah ini :

Nama : Andrianto Kusumo Wibowo
NIM : 32602100028
Judul Tugas Akhir : Implementasi Deep Learning PIX2PIX GAN untuk Restorasi Citra Sidik Jari sebagai Upaya Penguatan Sistem Keamanan Biometrik dan Forensik Digital

Dengan bahwa ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 25 Agustus 2025

Yang menyatakan,



Andrianto Kusumo Wibowo

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan dibawah ini :

Nama : Andrianto Kusumo Wibowo

NIM : 32602100028

Program Studi : Teknik Informatika

Fakultas : Teknologi industri

Dengan ini menyatakan Karya Ilmiah berupa Tugas akhir dengan Judul : **Implementasi Deep Learning PIX2PIX GAN untuk Restorasi Citra Sidik Jari sebagai Upaya Penguatan Sistem Keamanan Biometrik dan Forensik Digital.** Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak bebas Royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dan pangkalan data dan dipublikasikan di internet dan media lain untuk kepentingan akademis selama tetap mencantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan agung.

Semarang, 25 Agustus 2025

Yang menyatakan,



Andrianto Kusumo Wibowo

KATA PENGANTAR

Segala puji penulis panjatkan ke hadirat Allah SWT atas rahmat dan karunia-Nya sehingga tugas akhir yang berjudul :

“Implementasi Deep Learning Pix2Pix GAN untuk Restorasi Citra Sidik Jari sebagai Upaya Penguatan Sistem Keamanan Biometrik dan Forensik Digital”

dapat diselesaikan. Tugas akhir ini salah satu syarat untuk menyelesaikan studi di Program Studi Teknik Informatika, Fakultas Teknologi Industri, Universitas Islam Sultan Agung Semarang.

Tugas akhir ini disusun sebagai bagian dari syarat untuk menyelesaikan studi pada Program Studi Teknik Informatika, Fakultas Teknologi Industri, Universitas Islam Sultan Agung (UNISSULA) Semarang.

Setulus hati penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Kedua orang tua tercinta, atas segala doa, kasih sayang, dan dukungan moral yang tiada henti selama proses studi ini berlangsung.
2. Prof. Dr. H. Gunarto, S.H., M.Hum selaku Rektor UNISSULA Semarang.
3. Dr. Ir. Hj. Novi Marlyana, S.T., M.T., IPU., ASEAN Eng. selaku Dekan Fakultas Teknologi Industri UNISSULA Semarang.
4. Dan dosen pembimbing saya, Ir. Sri Mulyono, M.Eng., yang telah memberikan arahan, bimbingan, dan ilmu yang sangat bermanfaat selama proses penulisan tugas akhir ini.

Penulis menyadari tugas akhir ini masih belum sempurna. Semoga karya ini dapat bermanfaat dan menjadi kontribusi di bidang teknologi biometrik dan pengolahan citra digital.

Semarang, 25 Agustus 2025

Hormat saya,



Andrianto Kusumo Wibowo

DAFTAR ISI


COVER	i
LEMBAR PENGESAHAN TUGAS AKHIR.....	iii
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	iv
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH.....	v
KATA PENGANTAR.....	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL.....	xi
ABSTRAK	xii
BAB I PENDAHULUAN	1
1. 1 Latar Belakang.....	1
1. 2 Perumusan Masalah.....	1
1. 3 Pembatasan Masalah.....	2
1. 4 Tujuan	2
1. 5 Manfaat.....	3
1. 6 Sistematika Penulisan	3
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	5
2. 1 Tinjauan Pustaka.....	5
2. 2 Dasar Teori.....	13
2.2.1 Kedudukan Citra Sidik Jari di Indonesia	13
2.2.2 Generative Adversarial Network (GAN)	13
2.2.3 Pix2Pix GAN	16
2.2.4 Peak Signal to Noise Rasio (PSNR)	25
2.2.5 Structural Similarity Indeks Measure (SSIM)	25
2.2.6 Contrastive Language-Image Pretraining for Image Quality Assessment (CLIP-IQA)	26
2.2.7 Learned Perceptual Image Patch Similarity (LPIPS)	27
2.2.8 Edge Preservation Score (EPS)	28
2.2.9 Edge Strength.....	29

BAB III METODE PENELITIAN.....	31
3. 1 Jenis Penelitian	31
3. 2 Desain Eksperimen	31
3. 3 Variabel Penelitian.....	32
3. 4 Instrumen Penelitian	32
3. 5 Alur Penelitian.....	33
3. 6 Teknik Evaluasi	33
3. 7 Kriteria Keberhasilan.....	34
BAB IV HASIL DAN ANALISIS PENELITIAN.....	35
4. 1 Hasil.....	35
4.1.1 Jenis Penelitian	35
4.1.2 Pengumpulan dataset.....	35
4.1.3 Preprocessing Data	36
4.1.4 Modeling.....	37
4.1.5 Data Keluaran.....	37
4. 2 Analisis Penelitian	41
4.2.1 Evaluasi Pelatihan.....	41
4.2.2 Evaluasi Keberhasilan.....	45
BAB V KESIMPULAN DAN SARAN.....	66
5. 1 Kesimpulan.....	66
5. 2 Saran	66
DAFTAR PUSTAKA	67
HALAMAN LAMPIRAN	72

DAFTAR GAMBAR


Gambar 2. 1 Jenis-Jenis Minutiae	9
Gambar 2. 2 Koordinat dan Arah Minutiae.....	9
Gambar 2. 3 Encoding Minutiae	10
Gambar 2. 4 Visualisasi Minutiae	11
Gambar 2. 5 Citra Original SOCOFing.....	12
Gambar 2. 6 Citra Altered SOCOFing	12
Gambar 2. 7 Arsitektur Generative Adversarial Network (GAN).....	14
Gambar 2. 8 Arsitektur Pix2Pix GAN.....	16
Gambar 2. 9 Flowchart Pix2Pix GAN	17
Gambar 2. 10 Arsitektur U-Net (Generator)	18
Gambar 2. 11 Flowchart U-Net (Generator)	19
Gambar 2. 12 Arsitektur Discriminator PatchGAN Pix2Pix	20
Gambar 2. 13 Flowchart PatchGAN (Discriminator)	21
Gambar 4. 1 Manipulasi Kerusakan Dataset.....	36
Gambar 4. 2 Input 1 Testing.....	38
Gambar 4. 3 Input 2 Testing.....	38
Gambar 4. 4 Input 3 Testing.....	39
Gambar 4. 5 Input 4 Testing.....	39
Gambar 4. 6 Input 5 Testing.....	40
Gambar 4. 7 Grafik Gen loss & Disc loss.....	43
Gambar 4. 8 Grafik SSIM	44
Gambar 4. 9 Grafik PSNR	44
Gambar 4. 10 Grafik Input Tes 1.....	47
Gambar 4. 11 Grafik Evaluasi Input Tes 2	49
Gambar 4. 12 Grafik Evaluasi Input Tes 3.....	50
Gambar 4. 13 Grafik Evaluasi Input 4	52
Gambar 4. 14 Grafik Evaluasi Input Tes 5.....	53
Gambar 4. 15 Grafik Training Gen Loos, Disk Loss, PSNR dan SSIM	55
Gambar 4. 16 Grafik Training overlay Gen Loos, Disk Loss, PSNR dan SSIM..	56

Gambar 4. 17 Grafik PSNR (training, validasi dan test).....	57
Gambar 4. 18 Grafik Gap PSNR (training dengan validasi dan test)	58
Gambar 4. 19 Grafik Gap SSIM (training, validasi dan test).....	59
Gambar 4. 20 Grafik Gap SSIM (training dengan validasi dan test).....	60
Gambar 4. 20 Grafik Gen loss, Disk loss dan Clip IQA	62
Gambar 4. 21 Overlay Grafik Gen loss, Disk loss dan Clip IQA	62
Gambar 4. 22 Grafik LPIPS, EPS, PSNR dan SSIM	63
Gambar 4. 23 Grafik overlay LPIPS, EPS, PSNR dan SSIM	64
Gambar 4. 24 User Interface Rekonstruksi & Evaluasi	65
Gambar 4. 25 Tampilan Proses Rekonstruksi	65



DAFTAR TABEL

Tabel 2. 1 Previous Research Analysis	6
Tabel 4. 1 Evaluasi Epoch Pelatihan	41
Tabel 4. 2 Evaluasi Model 40.....	46
Tabel 4. 3 Evaluasi Input Tes 2	48
Tabel 4. 4 Evaluasi Input Tes 3	50
Tabel 4. 5 Evaluasi Input Tes 4	51
Tabel 4. 6 Evaluasi Input Tes 5	53
Tabel 4. 7 Data training.....	55
Tabel 4. 8 Data training, validasi dan test.....	57
Tabel 4. 9 Data training, validasi dan test.....	59
Tabel 4. 9 Data testing.....	61



ABSTRAK

Sidik jari merupakan salah satu biometrik utama yang sangat sering dipergunakan baik untuk melakukan identifikasi ataupun autentiaksi. Citra sidik jari yang rusak sering kali menjadi permasalahan yang serius jika menyangkut identifikasi korban kecelakaan ataupun sebagai alat bukti tidak kejahatan pidana seperti pencurian dan pembunuhan. Menanggapi permasalahan tersebut, penelitian ini mengimplementasikan *Deep Learning Pix2Pix GAN* untuk restorasi citra sidik jari guna memudahkan pihak-pihak bersangkutan seperti halnya penegak hukum dalam mengidentifikasi korban kecelakaan atau mengungkap pelaku kejahatan pidana seperti halnya pembunuhan. *Deep Learning Pix2Pix GAN* menerapkan arsitektur *Generator* berupa (U-Net) dan *Discriminator* berupa PatcGAN yang dilatih menggunakan dataset SOCOFing dimana dataset tersebut sangat merepresentasikan gangguan forensik di dunia nyata khususnya di Indonesia. Evaluasi yang digunakan untuk analisa selama proses pelatihan menggunakan metrik PSNR, SSIM, *gen loss*, dan *disc loss* untuk melihat progres pembelajaran model. Metrik evaluasi CLIP-IQA, LPIPS, dan *Edge Preservation Score* (EPS) juga digunakan untuk menilai kinerja model saat proses testing dengan kriteria keberhasilan LPIPS berada dikisaran nilai 0,1 hingga kurang dari 0,3 serta EPS mendekati nilai 1 yang menunjukkan citra berhasil direstorasi dan kontur penting tetap dipertahankan.

Kata Kunci: Pix2Pix GAN, SOCOFing, Restorasi Citra, Sidik Jari, LPIPS, *Edge Preservation Score*.

ABSTRACT

Fingerprints are one of the main biometriks that are very often used for both identification and authentication. Damaged fingerprint images are often a serious problem when it comes to identifying accident victims or as evidence of criminal crimes such as theft and murder. In response to this problem, this study implements Deep Learning Pix2Pix GAN for fingerprint image restoration to make it easier for relevant parties such as law enforcement to identify accident victims or reveal perpetrators of criminal crimes such as murder. Deep Learning Pix2Pix GAN applies a Generator architecture in the form of (U-Net) and Discriminator in the form of PatcGAN trained using the SOCOFing dataset where the dataset is very representative of forensic disorders in the real world, especially in Indonesia. Evaluation used for analysis during the training process uses PSNR, SSIM, gen loss, and disc loss metrics to see the progress of model learning. The CLIP-IQA, LPIPS, and Edge Preservation Score (EPS) evaluation metrics were also used to assess model performance during the testing process. The success criteria for LPIPS are between 0.1 and 0.3, and EPS values approaching 1 indicate successful image restoration and preservation of important contours.

Keywords: Pix2Pix GAN, SOCOFing, Image Restoration, Fingerprint, LPIPS, *Edge Preservation Score*.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kemajuan ilmu dan teknologi yang berkembang era digital saat ini, kebutuhan akan sistem keamanan yang andal semakin meningkat dan mutlak dibutuhkan. Hal ini sejalan dengan berkembangnya transaksi elektronik, akses data, hingga penegakan hukum. Dalam hal keamanan, sistem keamanan yang berbasis biometrik telah banyak dikembangkan. Saat ini, dapat dikatakan bahwa seluruh masyarakat sudah menggunakan telepon pintar berbasis Android yang telah dilengkapi dengan berbagai fitur keamanan biometrik, seperti pemindai sidik jari (*finger print*), *face recognition* atau pengenalan wajah maupun autentikasi yang berbasis suara. Hal ini menandakan teknologi biometrik tidak hanya digunakan pada ranah instansi pemerintah saja atau penegakan hukum, tetapi juga telah menjadi bagian dari kehidupan sehari-hari masyarakat. Khususnya sidik jari, penggunaannya tidak hanya dipakai sebagai alat verifikasi identitas saja, tetapi juga dalam berbagai aspek penting seperti keamanan transaksi (Arifin 2022) maupun autentikasi dokumen. Ada juga kewajiban untuk mencantumkan sidik jari pada minuta akta oleh notaris (Dewi dkk. 2020).

Di Indonesia, penyelenggaraan identifikasi sidik jari telah memiliki dasar hukum yang kuat, hal ini tertuang dalam Undang-Undang Nomor 2 Tahun 2002 tentang Kepolisian Negara Republik Indonesia dan Undang-Undang Nomor 8 Tahun 1981 tentang Hukum Acara Pidana (Fatmawati 2020a). Dari sisi forensik, sidik jari juga mempunyai peran yang sangat penting karena dapat digunakan sebagai alat bantu investigasi sebuah kasus tindak pidana, seperti pada pengungkapan kasus tindak pidana pembunuhan (Winda dkk. 2019). Dan ditegaskan lagi bahwa sidik jari mempunyai kekuatan hukum yang kuat dan diakui secara luas di Indonesia, juga bernilai sebagai alat bukti yang sah (Ritonga dkk. 2024).

Sidik jari sendiri terbukti aman dan akurat untuk proses identifikasi dibandingkan dengan data biometrik lain seperti identifikasi menggunakan wajah

maupun iris mata seperti yang tertera pada penelitian (Gazali dkk. 2012). Keunggulan utama sidik jari terletak pada pola unik yang dimiliki setiap individu, sehingga memungkinkan proses identifikasi dilakukan dengan akurasi tinggi (Rowa dkk. 2021). Pada kenyataannya, kualitas citra sidik jari yang ditemukan di lokasi kejadian perkara tidak selalu ideal, citra sidik jari menjadi buram, terhapus sebagian, atau mengalami kerusakan. Permasalahan ini tentu berdampak pada turunnya akurasi sistem biometrik maupun efektivitas identifikasi forensik, sehingga diperlukan metode restorasi citra untuk meningkatkan kualitas gambar sidik jari.

Seiring berkembangnya teknologi, kecerdasan buatan (Artificial Intelligence/AI) telah mengalami perkembangan yang sangat pesat dan memberikan kontribusi besar pada bidang pengolahan citra, khususnya computer vision (Santosa dkk. 2021). *Generative Adversarial Network* (GAN), terutama yang model *Pix2Pix GAN* merupakan salah satu metode yang banyak digunakan. Metode ini dikenal mampu mempelajari hubungan antara dua citra (*before-after*) dan menghasilkan citra baru yang menyerupai data target (Henry, Natalie, & Madsen, 2021). Dengan memanfaatkan *Pix2Pix GAN* pada proses restorasi citra sidik jari diharapkan dapat menghasilkan gambar yang lebih jelas dan dapat digunakan untuk alat bantu investigasi yang lebih akurat, sehingga dapat mendukung kehandalan forensik digital.

1.2 Perumusan Masalah

Rumusan masalah dalam penelitian ini adalah sebagai berikut:

- Bagaimana menerapkan model *Deep Learning Pix2Pix GAN* menggunakan Dataset SOCOFing untuk restorasi citra sidik jari di Indonesia ?
- Bagaimana kinerja model *Deep Learning Pix2Pix GAN* menggunakan Dataset SOCOFing untuk restorasi citra sidik jari di Indonesia ?

1.3 Pembatasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

- Penelitian ini tidak membandingkan metode *Pix2Pix GAN* dengan metode GAN lain seperti SR-GAN, WGAN-GP, dan lain-lain)
- Penelitian ini menggunakan dataset SOCOFing yang berisikan citra sidik jari

dengan variasi kerusakan tertentu (*altered fingerprint*) untuk studi kasus permasalahan di Indonesia (blur/hilang sebagian).

- c. Citra yang dipakai untuk pelatihan data dibatasi hanya pada dataset yang digunakan untuk pelatihan sejumlah 3000 data dan 5 data (blur) untuk *testing*.
- d. Resolusi yang digunakan pada citra adalah 256x256 piksel standar.
- e. Penilaian Evaluasi kualitas hasil model berdasarkan nilai numerik yang dihasilkan oleh metrik evaluasi PSNR dan SSIM.

1.4 Tujuan

Penelitian ini bertujuan untuk:

- a. Merancang dan mengimplementasikan model *Deep Learning Pix2Pix GAN* menggunakan Dataset SOCOFing untuk restorasi citra sidik jari di Indonesia.
- b. Mengetahui kinerja model *Deep Learning Pix2Pix GAN* menggunakan Dataset SOCOFing untuk restorasi citra sidik jari di Indonesia.

1.5 Manfaat

Manfaat dari penelitian ini diantaranya :

- a. Menjembatani data yang kurang relevan dengan sistem biometrik yang telah ada di Indonesia.
- b. Menjadi literatur untuk pengembangan penelitian selanjutnya, khususnya di bidang forensik digital citra sidik jari.

1.6 Sistematika Penulisan

BAB I : PENDAHULUAN

Bab ini berisi tentang latar belakang dan penjelasan mengenai alasan diangkatnya judul penelitian ini yaitu: “Implementasi Deep Learning Pix2Pix GAN untuk Restorasi Citra Sidik Jari sebagai Upaya Penguatan Sistem Keamanan Biometrik dan Forensik Digital”. Selain latar belakang, pada BAB I ini juga menyajikan rumusan masalah, batasan masalah, serta tujuan penelitian.

BAB II : TINJAUAN PUSTAKA DAN DASAR TEORI

Pada BAB II ini membahas mengenai dasar teori atau landasan teori dan juga konsep konsep yang mendukung penelitian baik dari peneliti sebelumnya maupun dari konsep konsep paten. Pada bab ini akan dijelaskan analisa mengenai kebutuhan yang digunakan untuk melakukan perancangan pada arsitektur model serta pemodelan sistem.

BAB III : METODOLOGI PENELITIAN

BAB III ini berisi mengenai metode apa yang digunakan dalam penyusunan tugas akhir serta alur kerja dalam proses pemodelannya. Metode yang digunakan dalam penelitian ini meliputi jenis dan pendekatan penelitian, langkah-langkah eksperimen yang dilakukan, dataset yang digunakan, arsitektur pemodelan yang akan digunakan, serta metode untuk melakukan evaluasinya.

BAB IV : HASIL DAN PEMBAHASAN

Bab IV akan menyajikan hasil dari pelatihan dan juga pengujian model, termasuk metode evaluasi yang digunakan yaitu PSNR dan SSIM serta loss function generator dan discriminator. Dan tidak lupa juga akan menyajikan visualisasi hasil restorasi citra yang telah dibuat. Namun di bab ini tidak hanya menyajikan hal tersebut saja, tetapi juga akan menyajikan pembahasan yang mendalam mengenai interpretasi hasil dan juga evaluasi performa model berdasarkan komponen evaluasinya.

BAB V : KESIMPULAN DAN SARAN

Pada BAB V ini akan menyajikan kesimpulan dari hasil penelitian yang telah dilakukan dan juga menyajikan saran yang relevan untuk mengembangkan penelitian selanjutnya atau penerapannya di bidang praktis.

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Dalam pembuatan penelitian ini, dilakukanlah beberapa tinjauan pustaka untuk melihat dan mempelajari korelasi dan perkembangan yang telah dilakukan pada penelitian sebelumnya terkait dengan permasalahan kerusakan sidik jari pada latar belakang. Dalam perjalanannya sidik jari diolah dengan beberapa metode seperti pada awalnya (Afsar dkk. 2004) menggunakan AFIS berbasis minutiae dengan Gabor filter dan Crossing Number (CN). Kemudian berkembang lagi dimana terdapat permasalahan pada pattern matching dikarenakan kualitas gambarnya kurang jernih sehingga dilakukan penelitian untuk meningkatkan kualitas resolusi citra sidik jari.

Penelitian yang dilakukan oleh (Atul S dkk. 2013) bertujuan untuk meningkatkan kualitas citra sidik jari yang mengalami noise seperti buram agar lebih terlihat jelas menggunakan metode Gabor filter dikombinasikan dengan Crossing Number (CN) yang menghasilkan kualitas lebih baik. Penelitian ini membuahkan hasil yang bagus dimana kualitasnya meningkat secara signifikan.

Sejalan dengan perkembangan teknologi, sidik jari diteliti fitur pentingnya atau biasa disebut dengan minutiae. Pada penelitian yang dilakukan (Narayanan 2022) fitur sidik jari minutiae diekstrak untuk bisa lebih handal menggunakan preprocessing (segmentation & enhancement) dan filtering (CN method & false removal) yang menghasilkan ekstraksi minutiae yang andal. Pada penerapannya ternyata sistem minutiae masih jarang digunakan di Indonesia. Melihat tren ini, penelitian ini dibuat untuk melakukan restorasi citra sidik jari menggunakan metode deep learning Pix2Pix GAN untuk memudahkan sistem AFIS yang tidak menggunakan minutiae yang akan dibahas lebih lanjut dibawah.

Riset mengenai penelitian sebelumnya dilakukan dengan topik yang sama yakni dari segi metode hasil yang didapatkan ialah melakukan perubahan warna dari hitam menjadi berwarna dan juga melakukan normalisasi tulisan tangan menggunakan metode Pix2Pix GAN. Terlihat pada penelitian sebelumnya belum

ada yang menerapkan metode Pix2Pix GAN menggunakan data citra sidik jari khususnya di Indonesia. Berikut hasil dari tinjauan pustaka yang telah dipelajari.

Tabel 2. 1 *Previous Research Analysis*

No	Penulis	Judul	Metode	Data	Hasil
1	Hong-an Li, Min Zhang, Zhenhua Yu, Zhanli Li, Na Li (2021)	<i>An Improved Pix2Pix Model Based on Gabor Filter for Robust Color Image Rendering</i>	Pix2Pix + Gabor Filter + Least Squares GAN (LSGAN) + penalty term (WGAN-GP)	Summer Dataset (citra warna alami)	Kualitas visual meningkat (PSNR & SSIM lebih tinggi). Pelatihan lebih stabil dibanding Pix2Pix biasa.
2	Álvaro Barreiro-Garrido, Victoria Ruiz-Parrado, A. Belén Moreno, José F. Vélez (2024)	<i>A Pix2Pix Architecture for Complete Offline Handwritten Text Normalization</i>	Pix2Pix (modifikasi U-Net & PatchGAN) untuk normalisasi tulisan tangan	IAM, Bentham, Osborne	Efektif dalam normalisasi slope, slant, ascenders/descenders. Lebih unggul dari metode heuristik klasik.
3	Andrey Makrushin, Christian Rathgeb, Christoph Busch (2023)	<i>Data-Driven Fingerprint Reconstruction from Minutiae Based on Real and Synthetic Training Data</i>	Pix2Pix (modifikasi U-Net & PatchGAN), dengan encoding minutiae (directed line & pointing minutiae)	FVC200 2, FVC200 4, CrossMatch, syn50k (StyleGAN2-ada)	Pix2Pix mampu merekonstruksi sidik jari realistis dari minutiae. Model berbasis data sintetis mendekati performa data asli.

Tabel 2. 1 menampilkan tinjauan pustaka dari beberapa penelitian sebelumnya yang menampilkan tentang metode yang sama yang akan digunakan

pada penelitian ini yaitu menggunakan metode *Pix2Pix GAN*. Pada beberapa penelitian sebelumnya, menampilkan tentang beberapa pengguna metode *Pix2Pix GAN* untuk menyelesaikan beberapa kasus seperti pemberian warna pada gambar yang masih hitam putih dan juga normalisasi tulisan tangan.

Pada Tabel 2. 1 baris pertama menunjukkan penelitian yang dilakukan oleh Hong-an Li, Min Zhang, Zhenhua Yu, Zhanli Li, dan Na Li (Li dkk. 2022) di Negara Tiongkok pada sekitar tahun 2021 hingga 2022 yang mengangkat judul “*An Improved Pix2Pix Model Based on Gabor Filter for Robust Color Image Rendering*”. Penelitiannya memuat tentang penerapan sistem *Pix2Pix* yang digabungkan dengan metode *Gabor Filter* dan Juga *Least Square GAN (LSGAN)* serta *penalty term (WGAN-GP)* dengan dataset *Summer Dataset* untuk meningkatkan kualitas visual dan juga kestabilan proses pelatihan daripada hanya menggunakan metode *Gabor* atau salah satunya saja. Integrasi pada *Gabor filter* dan juga *Loss* secara signifikan meningkatkan kualitas dan stabilitas gambar warna. *PSNR* tertinggi yang didapatkan pada penelitian ini adalah angka 32,79 db dan juga *SSIM* tertinggi diangka 86,01%.

Pada tahun 2024 dilakukanlah penelitian dengan judul “*A Pix2Pix Architecture for Complete Offline Handwritten Text Normalization*” di Negara Spanyol oleh Alvaro Barreiro, Garrido Victoria Ruiz, Parrado A. Belen Moreno, dan juga oleh Jose F. Velez (Barreiro-Garrido dkk. 2024) yang memuat tentang implementasi *Pix2Pix* yang dimodifikasi dari (*U-Net + PatchGAN*) untuk melakukan normalisasi pada sebuah tulisan tangan. Pada penelitian ini menggunakan beberapa dataset seperti *IAM* yang mana merupakan skrip tulisan tangan dari dokumen nyata yang berbahasa inggris yang memiliki sekitar 115.320 kata, *Bentham* yang merupakan dokumen sejarah yang memiliki sekitar 11.473 kata, dan serta dataset *Osborne* yang mana merupakan skrip multibahasa pada tahun 1830 hingga 1883 yang memuat sekitar 7.149 kata di dalamnya. Tujuan dari penelitian ini ialah melakukan normalisasi tulisan tangan *offline* menggunakan metode *Pix2Pix* secara keseluruhan baik kemiringan huruf, ukuran huruf, maupun noise guna menggantikan prosedur heuristik konvensional/klasik. Dan hasil yang

didapatkan ialah *Pix2Pix* mampu melakukan normalisasi yang sangat dekat dengan metode heuristik konvensional/ klasik


Andrey Markrushin dkk.(2023) juga melakukan penelitian yang bertujuan untuk merekonstruksi sidik jari yang realistis hanya menggunakan peta minutiae saja yang terdapat di sidik jari di negara Jerman. Penelitiannya menggunakan dataset dari FVC2002, FVC2004, dan CrossMatch (yang biasa disebut “aug39k”) serta dataset syn50k (StyleGAN2-ada). Pada penelitian ini hasil yang didapatkan terbilang memuaskan karena model *Pix2Pix GAN* mampu merekonstruksi citra sidik jari pada peta minutiae secara realistis dengan *PSNR* dan *SSIM* yang tinggi dimana hasilnya sangat mirip dengan visual (Makrushin dkk. 2023).

Melihat tinjauan pustaka diatas mengenai penelitian yang telah dilakukan sebelumnya, di dapatkan hasil bahwa metode *Pix2Pix GAN* cocok digunakan untuk melakukan penelitian yang berfokus pada pemulihan citra khususnya citra sidik jari yang akan dilakukan pada penelitian kali ini. Adapun permasalahan umum yang ditemui dari literatur diatas dalam menangani citra adalah adanya resiko *overfitting*, dataset yang kecil dan terbatas, dan gambar uji hanya pada lingkungan yang terkendali bukan pada kondisi nyata. Seperti contohnya mengenai kasus yang sama pada penelitian yang dilakukan oleh (Makrushin dkk. 2023) memiliki beberapa permasalahan diantaranya ialah:

a. Tidak menggunakan citra rusak nyata

Dalam penelitian yang dilakukan oleh Markushin, input yang digunakan adalah peta minutiae yang mana hanya berupa titik-titik minutiae yang bersih yang ada di sidik jari yang mana telah dilakukan pemrosesan dan divisualisasikan. Minutiae sendiri merupakan sekumpulan titik-titik fitur yang terdapat pada sidik jari, yang mana titik-titik fitur lokal ini menjadi sebuah ciri khas pola yang terdapat pada sidik jari yang dimiliki setiap individu. Minutiae sendiri memiliki beberapa jenis pada polanya, seperti: *Ridge Ending* (ujung garis), Bifurkasi atau biasa dikenal dengan percabangan, *Short Ridge* (garis pendek) biasa dikenal juga dengan dot/titik, *Island* yang terlihat seperti gambar pulau atau lingkaran tertutup yang kecil, dan juga terdapat jenis *Crossover* yang memiliki tampilan seperti persilangan garis yang bisa dilihat dari gambar 2. 1 di bawah. Kumpulan dari titik-titik tersebut adalah

yang dinamakan menjadi peta Minutiae. Peta Minutiae ini memiliki koordinat titik (x,y) sama halnya dengan peta geografis yang kita kenal selama dan juga arah garis maupun titiknya yang biasanya berupa derajat seperti terlihat pada gambar 2. 2 di bawah.



Gambar 2. 1 Jenis-Jenis *Minutiae* (Zaeri 2011)




Gambar 2. 2 Koordinat dan Arah *Minutiae* (Zaeri 2011)

Pada penelitian ini tidak menggunakan citra sidik jari yang rusak sebagai inputnya seperti yang ada di dataset SOCOFing. Padahal dalam praktiknya, sering kali terjadi noise struktural seperti garis yang terputus ataupun distorsi lokal seperti goresan bahkan terkadang terdapat cacat parsial dimana sebagian area sidik jari hilang. Namun, penelitian yang telah dilakukan oleh Markushin tidak dapat langsung digunakan untuk memulihkan citra sidik jari rusak secara visual misalnya dalam kasus forensik digital.

b. Keterbatasan input tipe tunggal


Pada metode yang digunakan di penelitian ini input yang dapat diterima ialah dalam bentuk “peta minutiae” yang harus sudah dikonversi menjadi gambar *encoding* seperti terlihat pada gambar 2. 3 di bawah. Namun pada dasarnya input ini sangat terstruktur dan tidak alami. Hal ini menyebabkan permasalahan baru saat pengguna tidak memiliki akses ke software ekstraksi minutiae yang menyebabkan pengguna tidak dapat menggunakan model yang dikembangkan ini.



Gambar 2. 3 *Encoding Minutiae* (Jain dkk. 2013)

c. visualisasi minutiae yang subjektif

Pada penelitian yang dikembangkan oleh Makrushin, ia membuat dua jenis *encoding* visual untuk peta minutiae ini. Tipe pertama ialah *Direct Lines (DL)* yang mana berupa garis kecil yang menunjukkan arah titik minutiae dan tipe yang kedua ialah *Pointing Minutiae* yang mana tipe ini merupakan kombinasi antara kotak dan garis arah seperti terlihat pada gambar 2. 4 mengenai visualisasi *Minutiae*.



Gambar 2. 4 Visualisasi *Minutiae* (Zaeri 2011)

Namun, pada penelitian yang ia kembangkan ini tidak memiliki standar universal yang mengatur bagaimana minutiae harus divisualisasikan. Hal tersebut memiliki dampak yang terasa antara lain: akan sulit untuk melakukan replikasi penelitian jika encoding tidak ditiru 100% identik, dan pengguna dengan *encoding* yang berbeda akan menghasilkan citra yang tidak akurat atau bahkan salah interpretasi. Disisi lain, *Sokoto Coventry Fingerprint Dataset (SOCOFing)* ini merupakan kumpulan dari citra sidik jari guna memenuhi kebutuhan pengembangan dan juga evaluasi mengenai sistem pengenalan biometrik. Dataset ini dikembangkan oleh seorang bernama Ahmad F. Abusshariah bersama sama dengan koleganya yang berasal dari *Sokoto State University*, yang berada di Nigeria serta bekerjasama dengan *University of Warwick* yang berlokasi di Coventry (UK) (Shehu dkk. 2018). Data set SOCOFing ini dapat diakses secara publik melalui internet, dimana data set ini berisikan 600 orang partisipan. Sehingga data set ini berisi citra original sidik jari berjumlah 6.000 citra, yang mana tiap-tiap partisipan menyumbangkan 10 jarinya untuk diambil citra sidik jarinya. Dataset SOCOFing ini merupakan perpaduan lengkap yang memiliki citra ori/asli dengan alter atau yang mengalami manipulasi berupa distorsi maupun noise yang dapat dilihat pada Gambar 2. 5 untuk citra asli/original dan juga Gambar 2. 6 untuk citra *Altered* atau yang telah dimanipulasi. Manipulasi yang dilakukan berupa: *Central Rotation* (rotasi bagian tengah pola garis), *Obliteration* (kerusakan sebagian pola garis), dan juga *Z-Cut* (pemotongan garis yang dilakukan secara diagonal). Jumlah total dari

dataset SOCOFing adalah 55.000 citra sidik jari dengan format (.BMP) yang mana memiliki resolusi setiap citranya ialah 96x103 piksel.



Gambar 2. 5 Citra Original SOCOFing (Shehu dkk. 2018)



Gambar 2. 6 Citra Altered SOCOFing (Shehu dkk. 2018)

d. Validasi dengan dataset terbatas

Dataset yang digunakan untuk mengembangkan penelitian ini tidak banyak dipakai di Indonesia dan juga Makrushin menggunakan dataset buatan sendiri yang bernama Anguli yang mana bukan *open-source*. Berbanding terbalik dengan dataset SOCOFing yang mana merupakan dataset *open-source* yang ringan, dan juga memiliki citra sidik jari *altered* yang merepresentasikan gangguan forensik dunia nyata khususnya di Indonesia. Dalam beberapa kasus pembunuhan contohnya, seringkali pada tempat kejadian perkara (TKP) ditemukan sidik jari yang mana sidik jari tersebut merupakan kunci utama dan satu-satunya petunjuk untuk mengungkap identitas pelaku pembunuhan ini. Namun dalam prakteknya, kunci utama (sidik jari) untuk mengungkap identitas pembunuh tersebut ditemukan dalam kondisi terhapus sebagian, ada yang terkena noda darah maupun air yang menyebabkan sama pada citra sidik jari yang akan diambil.

2.2 Dasar Teori

2.2.1 Kedudukan Citra Sidik Jari di Indonesia


Sidik jari merupakan salah satu biometrik yang sudah dikenal luas khususnya di Indonesia. Sidik jari sendiri di Indonesia digunakan untuk menangani banyak aktivitas seperti transaksi jual beli, sebagai salah satu identifikasi keamanan, dan juga digunakan untuk menyelesaikan masalah untuk kasus pidana di ranah hukum sebagai alat bukti untuk mengungkapkan kasus baik pencurian maupun pembunuhan (Fatmawati 2020b).

Sidik jari digunakan untuk banyak keperluan dikarenakan dalam daktiloskopi (ilmu yang mempelajari tentang sidik jari) sidik jari memiliki beberapa fakta diantaranya ialah bahwa sidik jari yang terdapat pada setiap individu tidak akan pernah berubah selama hidup dan bahwa sidik jari yang terdapat pada setiap individu tidak akan pernah sama pada setiap individunya pada tanda-tanda (titik-titik persamaan) sidik jarinya (Widiatmika 2015). Sehingga dapat disimpulkan bahwa sidik jari memiliki kualifikasi dan aman untuk dijadikan alat bukti maupun alat identifikasi bahkan sebagai alat keamanan dalam berbagai hal karena terbukti memiliki akurasi yang tinggi dan otentik.

2.2.2 Generative Adversarial Network (GAN)

Pada tahun 2014, Ian Goodfellow bersama rekannya memperkenalkan metode *Generative Adversarial Network (GAN)* pertama kali melalui penelitian berjudul "*Generative Adversarial Nets*". Pada penelitiannya ini Ian Goodfellow mengusung konsep yang unik dimana ia memperkenalkan konsep pembelajaran dengan 2 pemain (pemain merupakan penggambaran 2 jaringan saraf biasa dikenal dengan game teoritik) yang mana satu pemain akan memerankan peran Generator (G) dan pemain lainnya akan memerankan peran *Discriminator (D)*. Aturan dari permainan ini ialah para pemain harus saling bersaing dalam proses pelatihannya dan proses ini dinamakan *adversarial* (Cohen dkk. 2023). Peran utama si Generator (G) ialah untuk mencoba membuat sebuah data tiruan yang menyerupai data asli, sedangkan untuk pihak *Discriminator* berperan sebagai polisi yang mana mencoba untuk membedakan antara data asli dan data palsu.

Tujuan dari proses yang dilakukan dalam GAN ialah untuk membuat sampel baru dimana sampel baru tersebut susah dibedakan atau bahkan tidak bisa dibedakan keasliannya oleh discriminator.



Gambar 2. 7 Arsitektur *Generative Adversarial Network* (GAN) (Santosa dkk. 2021)

Pada Arsitektur *Generative Adversarial Networks* (GAN) memiliki skema dimana *input* yang akan diterima generator berupa vektor acak dari *latent space*. Dimana *latent space* ini merupakan suatu representasi kode tersembunyi yang nantinya akan dipelajari menjadi gambar yang realistis. Kemudian gambar yang dihasilkan oleh generator tersebut akan dikirimkan ke *discriminator*, sehingga pihak *discriminator* nantinya akan memiliki dua *input* yang salah satunya ialah dari generator dan satunya merupakan gambar asli dari dataset. Tugas dari *discriminator* ini ialah untuk menjadi petugas pemeriksaan untuk mengecek semua *input* yang masuk kepadanya apakah itu asli (*real*) atau palsu (*fake*). Kemudian *discriminator* akan menghasilkan *output* berupa probabilitas antara 0 (*fake*) dan 1 (*real*). Dan akan terdapat dua *loss* yang mana *loss* generator akan muncul disaat generator gagal untuk menipu *discriminator* dan *loss discriminator* akan muncul saat *discriminator* salah menebak gambar itu asli atau palsu seperti yang terlihat pada gambar 2. 7 diatas.

Dalam menjalankan fungsinya, arsitektur GAN ini memiliki beberapa komponen yang bekerja di dalamnya yang mana terlihat seperti gambar dan penjelasan diatas. Berikut ialah penjelasan untuk beberapa komponen yang berperan dalam arsitektur *Generative Adversarial Network* (GAN) tersebut:

1. Generator

Generator sendiri sering dikenal sebagai pemalsu yang kreatif diranahnya yang mana merupakan *neural network* atau jaringan saraf yang bertugas untuk menghasilkan suatu data sintesis dari suatu *input* yang berupa suatu vektor acak. Seperti yang kita tahu sebelumnya, tujuan dari generator ini ialah untuk menghasilkan suatu data yang seolah-olah berasal dari data asli.


Dalam prosesnya, generator akan melakukan beberapa tahapan untuk menghasilkan tiruan. Tahap-tahap atau lapisan-lapisan yang akan dilalui secara umum ialah pada lapisan awal setelah generator mendapatkan *input*, generator akan membentuk kerangka kasar citra tersebut untuk mengetahui gambaran bentuk dan rupa *input* yang dimasukan. Kemudian di lapisan ke-dua, generator akan memperbesar dan memperjelas detail pada citra tersebut agar bisa dipelajari secara menyeluruh. Setelah detail diperbesar dan diperjelas, lapisan yang dilalui selanjutnya ialah untuk menambahkan warna dan tekstur untuk dapat membuat citra yang menyerupai data asli. Selanjutnya generator akan menghasilkan citra akhir. Begitulah perjalanan atau proses yang dilalui pada generator saat bekerja sebelum hasilnya dikirimkan kepada *discriminator* untuk dinilai.

2. Discriminator

Discriminator merupakan *neural network* atau biasa dikenal dengan jaringan saraf di Indonesia, memiliki peranan yang bertugas untuk membedakan apakah data yang telah diterima merupakan data asli dari dataset atau data palsu yang dikirimkan oleh generator berupa data sintesis. Dalam prosesnya, *discriminator* bekerja dalam beberapa tahap atau lapisan. Dalam tahap pertama setelah *discriminator* menerima data dari generator maupun dataset, *discriminator* akan memindai bagian-bagian kecil dari citra yang telah masuk untuk mengecek apakah ada perbedaan dari dua citra yang telah diterimanya. Setelah melakukan pemindaian tersebut akan muncul suatu informasi, tahap selanjutnya *discriminator* akan menyusun informasi tersebut menjadi suatu kesimpulan yang nantinya akan digunakan untuk menilai mana dari dua citra yang asli atau palsu. Kemudian di tahapan akhir, *discriminator* akan mengeluarkan nilai 0 untuk citra yang dinilai palsu/*fake* dan 1 untuk gambar yang dinilai asli/*real*.

2.2.3 Pix2Pix GAN

Seperti yang telah kita ketahui diatas mengenai *Generative Adversarial Network (GAN)* yang merupakan suatu model generatif yang terdiri dari dua komponen atau jaringan saraf (*neural network*) yang saling bersaing dalam proses kerjanya.




Gambar 2. 8 Arsitektur Pix2Pix GAN (Al-Shahad dkk. 2025)

Penerapan *cGAN (Conditional GAN)* pada *Pix2Pix* ialah dimana GAN akan dilatih dengan *input* tertentu (x) untuk menghasilkan suatu *output* (y) yang sesuai. *Pix2Pix* sendiri merupakan metode yang dikembangkan untuk menyelesaikan suatu permasalahan *image-to-image translation*. Proses *image-to-image translation* sendiri merupakan proses untuk mengubah citra ke bentuk citra lain yang secara semantik berpasangan. Metode tersebut juga dibahas pada penelitian (Tahmid dkk. 2023) sebagai varian dari *Generative Adversarial Network* yang bekerja dalam suatu konteks pembelajaran terarah (*supervised learning*). *Pix2Pix* sendiri memiliki keunikan dalam menjalankan prosesnya dibandingkan dengan GAN konvensional yang mana menghasilkan citranya melalui input acak (*noise*), sedangkan *pix2pix* akan menggunakan pasangan citra input dan citra target sebagai data pelatihannya.

Tujuan dari proses yang dilakukan pada *pix2pix* ini ialah untuk membangun model yang dapat mempelajari transformasi dari *input* ke *output* dengan konten dan struktur yang sesuai. *Pix2Pix* terdiri dari dua komponen penyusun utama yakni ada

Generator dan juga *Discriminator*. Fungsi dan tujuan dari dua komponen tersebut juga sama halnya dengan yang ada di dalam GAN konvensional yang mana generator bertujuan untuk menghasilkan citra baru berdasarkan *input* yang telah diberikan berupa citra *Altered* (citra sidik jari yang rusak). Sedangkan untuk *discriminator* sendiri bertujuan untuk mengevaluasi sampai sejauh mana citra yang dihasilkan oleh generator (*generator output*) menyerupai citra yang asli (*original input*). Namun pada penerapannya, *Pix2Pix* menggunakan *U-Net* untuk generatornya dan juga *Patch GAN* untuk *discriminator*nya seperti yang terlihat pada gambar 2. 8 diatas.




Gambar 2. 9 Flowchart Pix2Pix GAN (Yang dan Gao 2022)

U-Net ini memiliki keunggulan untuk menjaga informasi spasial berkat adanya teknologi *skip connections*. Sedangkan untuk *Discriminator*nya, *Pix2Pix* telah mengadopsi konsep *PatchGAN*. *PatchGAN* ini akan melakukan tindakan klasifikasi otentisitas bukan dari keseluruhan gambar, namun pada bagian kecil (*patch*) dari suatu citra seperti yang terlihat pada Gambar 2. 9 diatas. Tujuan dari adopsi konsep *PatchGAN* ini ialah untuk memungkinkan model yang dibangun

menjadi lebih peka terhadap detail lokal seperti: tepi, garis-garis halus, ataupun tekstur dari suatu citra untuk bisa mendapatkan hasil yang otentik terlebih untuk pengerjaan pemulihan citra sidik jari.


Seperti yang telah diketahui diatas, pix2pix memiliki dua komponen utama yaitu generator dan juga *discriminator*. Pada penerapannya, terdapat beberapa struktur arsitektur yang menyusun dua komponen tersebut antara lain:

1. *Generator*



Gambar 2. 10 Arsitektur U-Net (Generator) (Nazeri dkk 2018)

Pada arsitektur yang terdapat pada generator *Pix2Pix GAN* menggunakan *U-Net*, dimana pengertian dari *U-Net* ialah jaringan konvolusional (*convolutional neural network/CNN*) yang memiliki susunan bentuk *encoder-decoder* simetris dengan *skip connections* seperti pada Gambar 2. 10 tentang arsitektur *U-Net*. *CNN* sendiri merupakan jaringan saraf tiruan yang memang dirancang secara khusus untuk menangani pemrosesan data yang berbentuk grid seperti gambar dan video. *U-Net* pertama kali diperkenalkan oleh Olaf Ronneberger dkk (Weng dkk. 2021) pada tahun 2015 guna tugas segmentasi citra medis. Dan semakin berjalannya waktu, *U-Net* digunakan secara luas untuk melakukan berbagai macam tugas pemetaan piksel ke piksel termasuk dalam *image-to-image translation* yang digunakan pada *Pix2Pix*.




Gambar 2. 11 Flowchart U-Net (Generator) (Nazeri dkk. 2018)

Pada struktur *U-Net*, genertor memiliki beberapa bagian utama diantaranya ada *encoder*, *decoder*, dan juga *skip connections*. *Encoder (Downsampling Path)* atau biasa dikenal dengan *contracting path* memiliki tugas untuk mengekstrak fitur yang penting dari gambar *input* yang mana caranya ialah dengan menurunkan resolusi dari gambar dan memperluas ke dalam fitur (*channels*). Jadi semakin dalam layernya, akan semakin kecil ukuran spasialnya namun akan semakin kaya juga fitur abstraknya. Sedangkan untuk *Decoder (Upsampling Path)* atau biasa dikenal dengan *expanding path* memiliki fungsi untuk membuat atau membangun kembali citra dari fitur-fitur abstrak yang telah dihasilkan oleh *encoder* dengan cara mengembalikan resolusi gambar ke ukuran aslinya. *Decoder* juga dibantu oleh *skip connections* untuk mendapatkan informasinya yang akan digunakan kembali untuk membangun kembali detail spasialnya seperti yang terlihat pada gambar 2. 11 diatas.

Skip connections sendiri merupakan penghubung langsung antara layar *encoder* dan layar *decoder* yang berada pada kedalaman yang sama. Pada


mekanisme ini fitur dari layer awal yang masih memiliki informasi spasial yang kaya diperbolehkan untuk ditransfer langsung ke layer akhir, tanpa harus melalui jalur kompresi. Terdapat beberapa fungsi dari *skip connections* ini diantaranya ialah untuk mempertahankan detail spasial yang mungkin hilang saat melakukan proses *downsampling* di *encoder*, membuat model lebih cepat belajar, dan juga mengurangi resiko kehilangan gradien (*vanishing gradient*) saat proses penghitungan gradien turunan dari fungsi kerugian terhadap bobot jaringan (*backpropagation*).

2. Discriminator



Gambar 2. 12 Arsitektur *Discriminator PatchGAN Pix2Pix* (Nazeri dkk. 2018)

Pada discriminator yang terdapat pada *Pix2Pix GAN* menggunakan konsep pendekatan *PatchGAN* yang diperkenalkan sebagai metode yang efektif untuk menilai citra apakah setiap bagian-bagian kecil dari citra yang dihasilkan oleh generator memiliki tekstur yang realistis atau tidak (Tahmid dkk. 2023). Dalam *Pix2Pix* dilakukan pendekatan untuk mengevaluasi citra berdasarkan *patch* lokal daripada melakukannya secara keseluruhan seperti Gambar 2. 12 diatas. Dalam pendekatan tersebut, diskriminator tidak memberikan satu *output* asli atau palsu untuk seluruh gambar, namun akan memberikan peta prediksi dua dimensi (biasanya 30x30 nilai), dimana setiap elemen akan mewakili setiap keputusan asli atau palsu pada satu *patch*.



Gambar 2. 13 Flowchart PatchGAN (Discriminator) (Nazeri dkk. 2018)

Proses-proses yang dilalui pada tahapan *discriminator* ini setelah menerima citra *input* dan target atau hasil dari generator, kedua citra tersebut nantinya akan digabungkan dan dimasukkan ke dalam suatu jaringan konvolusional (*Conv2D*) bertingkat hingga menghasilkan peta nilai jaringan *discriminator* ini memiliki beberapa lapisan di dalamnya yang akan secara bertahap mengecilkan dimensi spasial dan akan memperbesar kedalaman fiturnya seperti yang terlihat pada gambar 2. 13 diatas. Pada setiap lapisan memiliki tugas dan fungsinya masing-masing diantaranya:

a. Lapisan Pertama

Pada lapisan pertama ini terdapat *Conv2D + LeakyReLU* yang mana memiliki fungsi untuk menangkap bentuk dasar dari citra dan juga menggunakan fungsi yang

bernama *LeakyReLU* agar bisa membantu untuk mengenali pola dan juga garis meskipun belum menggunakan normalisasi (Xu dkk. 2015). Persamaan Conv2D sebagai berikut :

$$Z_{i,j,k} = \sum_{m=0}^{k_h+1} \sum_{n=0}^{k_w-1} \sum_{c=0}^{C_{in}-1} W_{m,n,c,k} \cdot x_{i+m,j+n,c} + b_k \quad (1)$$

Keterangan:

- $Z_{i,j,k}$ = nilai output feature map pada koordinat (i,j) di channel/filter ke-k.
- $\sum_{m=0}^{k_h+1} \sum_{n=0}^{k_w-1}$ = penjumlahan di dalam kernel (tinggi k_h , lebar k_w).
- $\sum_{c=0}^{C_{in}-1}$ = penjumlahan di semua channel *input* (misal *RGB* berarti 3 channel).
- $W_{m,n,c,k}$ = bobot *kernel* di posisi (m,n) untuk channel *input* ke-c dan *filter output* ke-k.
- $x_{i+m,j+n,c}$ = nilai piksel *input* pada posisi (i+m,j+n) di channel ke-c.
- b_k = bias untuk filter ke-k.

b. Lapisan Kedua

Pada lapisan kedua ini terdapat *Conv2D + BatchNormalization + LeakyReLU* yang mana menyebabkan proses yang dilakukan akan menjadi semakin dalam dan juga kompleks. *BatchNormalization* ini merupakan teknik yang digunakan untuk membantu proses belajar menjadi lebih stabil dan juga menjadi cepat. Dan disini *LeakyReLU* juga digunakan untuk menjaga agar informasi tetap mengalir meskipun memiliki nilai negatif seperti yang terlihat pada persamaan 1 dibawah. Dengan nilai α 0,2 yang bertujuan agar neuron tidak mati (Xu dkk. 2015). Persamaan *LeakyReLU* adalah sebagai berikut :

$$f(x) = \begin{cases} \alpha x, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

c. Lapisan Terakhir

Sedangkan pada tahap terakhir ini proses tidak lagi memproses seluruh citra sekaligus, namun proses yang dilakukan ialah membagi citra menjadi bagian-bagian yang lebih kecil atau biasa disebut dengan *patch*. Kemudian *patch* ini akan dinilai keasliannya, apakah ini asli atau palsu. Setelah itu, hasil akhirnya akan

berupa sebuah peta kecil yang memiliki nilai antara 0 dan 1 yang akan menunjukkan mana bagian citra yang asli dan mana bagian citra yang palsu.

3. Loss Function

Loss function atau biasa dikenal dengan fungsi *loss* merupakan salah satu komponen yang krusial yang terdapat dalam pembelajaran model yang berbasis *deep learning*. *Loss* ini nantinya akan digunakan untuk mengukur perbedaan antara hasil prediksi yang dibuat oleh model dengan data asli yang sebenarnya (*ground truth*). Hal tersebut nantinya akan digunakan sebagai umpan balik untuk memperbarui bobot jaringan pada saat proses *backpropagation*.

Loss Function yang terdapat pada arsitektur *Pix2Pix GAN* yang mana merupakan kategori dari *Conditional Generative Adversarial Network (Cgan)* memiliki peran ganda yang mana model ini memiliki dua jaringan yang saling berkompetisi untuk mengalahkan satu sama lain yaitu: Generator (G) dan *Discriminator (D)*. Oleh karenanya, akan muncul dua fungsi *loss* utama juga di dalamnya yang mana masing-masing fungsi *loss* utama tersebut memiliki peran tersendiri dalam mengoptimalkan proses pelatihan modelnya. Fungsi *loss* utama tersebut ialah *Generator Loss* dan juga *Discriminator Loss*.

a. Generator Loss

Tugas dari generator ialah untuk menghasilkan gambar yang mana harus menyerupai citra dari target aslinya. Oleh karena itu, digunakanlah dua jenis fungsi *loss* yaitu: *Adversarial Loss* dan juga *L1 Loss*. Persamaannya adalah sebagai berikut

$$\mathcal{L}_G(\text{total}) = \mathcal{L}_{GAN}(G, D) + \lambda \cdot \mathcal{L}_{L1}(G) \quad (3)$$

Adversarial Loss sendiri berfungsi untuk membuat generator dapat menghasilkan gambar yang realistis hingga titik dimana *discriminator* mengira jika citra yang telah dihasilkan oleh generator adalah citra asli. Agar *discriminator* bisa memberikan label “asli/real” terhadap hasil buatan generator, maka diterapkanlah fungsi tersebut melalui *binary-cross-entropy*. Seperti yang telah dijelaskan oleh Wang dkk (Wang dkk. 2018), untuk pendekatan *Adversarial Loss* yang dilakukan di dalam *conditional generative adversarial network (cGAN)* dapat secara signifikan meningkatkan kualitas citra hasil bukan hanya dari kesamaan piksel, namun dengan mempertimbangkan distribusi dari semantik gambar.

L1 Loss sendiri atau *Mean Absolute Error (MAE)* digunakan dalam metode untuk memastikan bahwasannya citra hasil dari generator tidak hanya realistis secara visual, namun juga mirip secara piksel dengan citra target. Pada *L1 loss* ini akan dilakukan perhitungan untuk menghitung rata-rata dari nilai absolut selisih antara setiap piksel pada citra prediksi dan juga tentunya dengan citra target. Dalam metode *context encoder* yang dilakukan dan diterapkan oleh (Pathak dkk. 2016), fungsi ini terbukti untuk mendorong generator dalam menghasilkan citra yang memiliki struktur yang tajam dan juga memiliki bentuk sama dengan citra aslinya. Sehingga jika kedua fungsi ini *Adversarial Loss* dan juga *L1 Loss* digabungkan akan mendapatkan fungsi dari *generator loss* dapat menipu *discriminator* secara akurat seperti terlihat pada persamaan nomor (1) diatas.

Penggabungan kedua *loss* ini sangat penting terutama dalam aplikasi yang digunakan untuk melakukan restorasi citra sidik jari, yang mana membutuhkan perhatian lebih pada tekstur, struktur lokal, dan juga kontur halus yang sangat menentukan dalam hal rekonstruksi. Dengan pola *loss function* ini, model akan dapat belajar banyak hal dengan cara memperhatikan detail kecil seperti minutiae maupun ridge dan tidak hanya untuk meniru saja.

b. *Discriminator Loss*

Fungsi *loss* yang terdapat pada *discriminator* ini berfungsi untuk melakukan perhitungan keakuratan *discriminator* dalam mengenali citra asli sebagai *real* dengan label 1 dan citra yang palsu sebagai *fake* dengan label 0. Seperti yang kita tahu sebelumnya bahwa *discriminator* ini memiliki tugas dan fungsi untuk membedakan citra asli dan citra yang dihasilkan oleh generator. Dengan fungsi *loss* ini, *discriminator* akan dilatih untuk lebih meningkatkan kemampuannya dalam mengenali dan menilai perbedaan antara citra asli ataupun citra palsu. Selain melatih performa *discriminator*, fungsi *loss* yang terdapat pada *discriminator loss* ini juga memiliki peran dan andil yang penting dimana fungsi *loss* ini akan menjaga keseimbangan tekanan antara generator dan juga *discriminator* secara kompetitif dengan tujuan untuk membuat generator dapat menghasilkan gambar atau citra yang semakin baik.

2.2.4 Peak Signal to Noise Rasio (PSNR)

Peak signal to Noise Ratio atau yang biasa dikenal dengan PSNR ini merupakan salah satu metrik yang digunakan untuk mengevaluasi kualitas citra atau video yang paling umum digunakan di dalam bidang pengolahan citra digital. Fungsi atau tugas dari PSNR ini ialah untuk mengukur tingkat kesamaan antara dua citra yang mana dilakukan dengan cara membandingkan sinyal maksimum terhadap gangguan atau *noise* yang mana timbul dari adanya perbedaan antara citra hasil rekonstruksi / hasil dari generator dengan citra aslinya. Dalam praktiknya, PSNR ini dihitung dengan rasio dari sinyal maksimum terhadap *Mean Squared Error (MSE)* antara dua citra. *MSE* ini ialah rata-rata dari kuadrat perbedaan nilai piksel antara citra asli dengan citra hasil rekonstruksi atau hasil dari generator seperti yang terlihat pada persamaan dibawah.

$$PSNR = 10 \cdot \log_{10}\left(\frac{MAX^2}{MSE}\right) \quad (4)$$

Menurut (Wolf dkk. 2009), perhitungan *PSNR* yang akurat harus mempertimbangkan beberapa aspek yang penting seperti halnya keselarasan spasial (*spasial alignment*), keselarasan temporal (*temporal alignment*), penguatan (*gain*), serta juga harus mempertimbangkan aspek *offset level* antara citra asli dan citra proses. Jika terjadi perbedaan yang kecil saja saat registrasi spasial atau pergeseran waktu (*delay*), itu dapat mempengaruhi nilai *PSNR* secara signifikan. Sehingga, proses kalibrasi menjadi penting dan krusial dalam halnya untuk menilai atau evaluasi *PSNR*.

Dalam konteks *Pix2Pix GAN*, *PSNR* menjadi tolak ukur dan metrik kuantitatif yang digunakan untuk mengevaluasi seberapa baik citra yang dihasilkan oleh generator dalam menyerupai target (*ground truth*). Nilai *PSNR* yang tinggi menjadi indikasi dan tolak ukur bahwasannya citra yang dihasilkan generator sangat mirip dengan citra asli (*ground truth*), yang mana artinya model telah berhasil melakukan pemetaan dari *input* ke target secara efektif.

2.2.5 Structural Similarity Indeks Measure (SSIM)

Structural Similarity Index Measure atau *SSIM* ini merupakan matrik yang berguna untuk menilai kemiripan dari dua citra secara struktural, yaitu citra hasil rekonstruksi dan juga citra asli (*ground truth*). *SSIM* ini sendiri memiliki konsep dimana dia akan memodelkan cara kerja sistem penglihatan yang dimiliki oleh manusia, dengan mempertimbangkan struktur lokal, kontras, dan lain halnya pada sebuah citra. *SSIM* ini akan menghasilkan nilai 0 sampai 1, yang mana jika nilainya mendekati nilai 1 artinya kemiripan strukturnya tinggi. Sehingga *SSIM* kerap kali dipilih untuk penelitian berbasis pemulihan citra, penghilangan *noise*, serta peningkatan resolusi gambar (Li dkk. 2022). Berikut merupakan persamaan yang digunakan dalam perhitungannya:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

Dimana:

- μ_x, μ_y merupakan rata-rata intensitas piksel,
- σ_x^2, σ_y^2 ialah varians masing-masing gambar,
- σ_{xy} adalah kovarians antara keduanya,
- C_1 dan C_2 adalah konstanta kecil untuk menstabilkan hasil ketika penyebut mendekati nol.

Pada penerapannya di dalam *Pix2Pix* ini, *SSIM* digunakan untuk melakukan evaluasi kemampuan generator dalam mempertahankan struktur spasial dari citra target. Hal ini menjadi penting jika digunakan dalam tugas-tugas yang bergantung pada keakuratan lokal seperti pemrosesan citra medis, astronomi, maupun biometrik (Xu 2024).

2.2.6 Contrastive Language-Image Pretraining for Image Quality Assessment (CLIP-IQA)

Dalam melakukan penilaian kualitas citra (*Image Quality Assessment / IQA*) tanpa adanya *ground truth* atau citra asli sebagai pembanding. CLIP-IQA menjadi salah satu metode evaluasi yang dapat digunakan. CLIP-IQA menerapkan kemampuan dari model CLIP atau biasa dikenal dengan *Contrastive Language – Image Pretraining* yang mana merupakan model yang dilatih untuk digunakan

menghubungkan informasi visual dari gambar dengan teks yang berada dalam satu ruang vektor. Menurut (Miyata 2023) CLIP-IQA merupakan metode evaluasi yang mengukur kualitas suatu citra dengan membandingkan kemiripan (*similarity*) antara representasi citra dengan representasi prompt teks, contohnya: “*this photo is good because it is sharp*” dan “*this photo is good because it is blurred*”. Pada penelitiannya diungkapkan tiga fitur utama untuk mengevaluasi antara lain: ketajaman (*sharpness*), *noise*, kecerahan (*brightness*). Pada metode evaluasi *CLIP-IQA* ini memiliki keunggulan dimana dalam penilaiannya ini tidak memerlukan gambar referensi atau target. Dengan pendekatan tersebut, metode *CLIP-IQA* dipilih untuk penelitian ini dikarenakan tidak membutuhkan *Ground Truth* (Wang dkk. 2023). Persamaannya adalah sebagai berikut :

$$p_k = \frac{\exp\left(\frac{f(I) \cdot f(T_k)}{\|f(I)\| \|f(T_k)\|_T}\right)}{\sum_{j=1}^K \exp\left(\frac{f(I) \cdot f(T_j)}{\|f(I)\| \|f(T_j)\|_T}\right)} \quad (6)$$

Keterangan:

- $f(I)$ = vektor embedding dari citra input setelah diproses encoder CLIP.
- $f(T_k) \rightarrow$ vektor embedding dari teks/prompt kualitas ke-k.
- s_k = nilai kesamaan (cosine similarity) antara citra dan teks kualitas ke-k.
- T = temperature parameter (mengatur ketajaman distribusi probabilitas).
- P_k = probabilitas bahwa citra memiliki kualitas sesuai label k.
- K = jumlah kategori/tingkatan kualitas yang dipertimbangkan.

2.2.7 Learned Perceptual Image Patch Similarity (LPIPS)

Learned Perceptual Image Patch Similarity atau biasa disebut dengan LPIPS merupakan metode evaluasi untuk melakukan penilaian terhadap kualitas citra yang berbasis referensi (*full-reference*). Metode evaluasi ini dirancang untuk mengukur seberapa mirip antara dua citra (citra *input* dan citra *output*) secara persepsi manusia dan telah terbukti lebih sesuai dengan penilaian dari subjektif manusia dalam banyak penelitian (Kashkarov dkk. 2024). Metode ini sangat berbeda dengan metode evaluasi *PSNR* dan juga *SSIM* yang lebih berfokus pada perbedaan piksel dan struktur citra. Penilaian yang dilakukan menggunakan metode evaluasi ini ialah

semakin kecil nilai *LPIPS*, maka semakin tinggi nilai *similarity* antara citra prediksi dengan citra *input*. Indikator metrik evaluasi ini berada pada rentang nilai 0 yang berarti nilai sama persis dari subjektif manusia dengan citra *inputnya*, rentang nilai 0,1-0,2 menandakan bahwa citra yang dihasilkan setelah rekonstruksi masih lumayan mirip dengan citra *input* dengan memiliki sedikit perbedaan, untuk rentang nilai $1 > x > 0,3$ mengartikan bahwasanya citra yang dihasilkan saat proses rekonstruksi guna melakukan restorasi citra sidik jari yang rusak ini memiliki tampilan yang cukup signifikan perbedaannya dibandingkan dengan *inputnya* dilihat dari sudut pandang subjektif manusia, sedangkan untuk nilai =1 artinya citra yang dihasilkan sudah tidak mirip sama sekali dengan citra *inputnya*. Itulah beberapa kriteria penilaian menggunakan metrik evaluasi ini (Ghazanfari dkk. 2023). Persamaannya adalah sebagai berikut :

$$\mathbf{LPIPS}(\mathbf{x}, \mathbf{y}) = \sum_l \frac{1}{H_l W_l} \sum_{h,w} w_l \|\boldsymbol{\varphi}_l(\mathbf{x})_{h,w} - \boldsymbol{\varphi}_l(\mathbf{y})_{h,w}\|_2^2 \quad (7)$$

Keterangan:

- $\boldsymbol{\varphi}_l(\cdot)$ → fitur map dari layer *l* (channel, height, width).
- $H_l W_l$ → dimensi spasial fitur di layer *l*.
- w_l → bobot layer *l* yang dipelajari (learned linear weights).
- $\|\cdot\|_2^2$ → kuadratis Euclidean distance antar fitur.

2.2.8 Edge Preservation Score (EPS)

Dalam mengukur dan menilai sejauh mana informasi struktur tepi dari sebuah citra dapat dipertahankan setelah dilakukan proses rekonstruksi atau transformasi, digunakanlah metode evaluasi yang dinamakan *Edge Preservation Score (EPS)*. Dalam metode *EPS* secara spesifik difokuskan pada faktor ketajaman serta keberadaan kontur lokal yang terdapat pada suatu citra. Secara umum perhitungan yang dilakukan pada metode *EPS* ini didasarkan pada korelasi antara peta tepi atau struktur tepi suatu citra referensi (*input*) dengan citra hasil. Proses yang dilakukan dalam metode ini ialah pertama citra akan diubah menjadi *grayscale* jika gambar masih dalam lingkungan berwarna, kemudian akan dilakukan pendeteksian struktur tepi menggunakan operator *Laplacian* (atau detektor lain seperti *Canny* dan *Sobel*),

dan ditahap akhir akan dihitung koefisien korelasi antara citra *input* dan citra *output* menggunakan persamaan dibawah .

$$EPS = \text{corrcoef}(E_{\text{input}}, E_{\text{output}}) \quad (8)$$

Pada persamaan (4) diatas, menunjukkan perhitungan koefisien korelasi dua citra (*input/output*) dan E_{input} dan E_{output} yang merupakan hasil *edge map* yang akan dihitung korelasinya antara representasi vektor dua peta tepi tersebut. Jika *EPS* menghasilkan nilai yang mendekati 1, maka dapat dikatakan struktur tepi sangat identik dari dua citra tersebut. Metrik evaluasi ini dinilai sangat cocok untuk penilaian hasil rekonstruksi citra sidik jari dikarenakan keberadaan garis tepi yang sangat halus serta ketajaman pada *ridge* atau garis-garis sidik jari merupakan komponen yang harus dipertahankan. Hal tersebut diperlukan dikarenakan pola garis pada sidik jari merupakan indikator untuk melakukan identifikasi identitas seorang individu. Menurut (Chen dkk. 2016) pada penelitiannya juga menyebutkan bahwa metrik EPS memiliki korelasi yang sangat amat baik terhadap persepsi visual manusia yang utamanya dapat dilihat di bagian penilaian ketajaman dan struktur lokalnya.

2.2.9 Edge Strength

Edge Strength digunakan untuk mengukur ukuran kuantitatif terhadap keberadaan garis tepi dan juga kontur yang terdapat pada suatu citra. secara mudah, metrik *Edge Strength* ini digunakan untuk menilai seberapa tajam (ketajaman) atau kejelasan suatu detail yang terdapat pada struktur lokal suatu citra yang mana sangat cocok digunakan untuk metrik evaluasi pada penelitian rekonstruksi citra sidik jari. Menurut (Sadykova dkk. 2017) pada penelitiannya yang berjudul “*Quality Assessment Metrics for Edge Detection and Edge-aware Filtering: A Tutorial Review*” menyatakan metrik ketajaman dan kualitas struktur tepi merupakan komponen yang sangat penting dalam hal menilai performa model pemrosesan citra yang dilatih berbasis *edge-aware*. *Edge-aware* merupakan suatu teknik pemrosesan citra yang bertujuan untuk mempertahankan struktur penting yang terdapat pada suatu citra baik berupa kontur maupun garis. Dalam konteks penelitian di bidang rekonstruksi citra sidik jari, *edge strength* digunakan untuk menilai dan

membandingkan seberapa baik model dapat mempertahankan dan meregenerasi kontur dan struktur detail pada citra sidik jari. Pada penilaian atau evaluasinya menggunakan *Edge Input Strength* yang menjadi acuan awal dari kualitas citra sidik jari baik dari struktur detail dan juga garis konturnya, kemudian akan dibandingkan menggunakan *Edge Output Strength* yang merupakan nilai pembandingan kinerja model dalam meregenerasi dan mempertahankan kontur maupun detail strukturnya. Kriteria dapat dikatakan membaik jika nilai hasil (*Edge Output Strength*) lebih tinggi dibanding dengan nilai acuan awal (*Edge Input Strength*) (Vikram dkk. 2015). Persamaannya adalah sebagai berikut :

$$\text{EdgeStrength}(x,y) = \sqrt{(f_x(x,y))^2 + (f_y(x,y))^2} \quad (9)$$

Keterangan:

- f_x dan f_y adalah turunan/derivatif citra dalam arah *horizontal* dan *vertikal* (misalnya hasil operator *Sobel* atau *Prewitt*).
- Rumus ini menunjukkan seberapa tajam perubahan intensitas pada titik (x,y) .

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Dalam penelitian yang akan dilakukan kali ini termasuk dalam jenis penelitian eksperimen kuantitatif. Tujuan dari penelitian yang dilakukan kali ini adalah untuk menguji implementasi metode *Pix2Pix Generative Adversarial Network (GAN)* dalam melakukan restorasi citra yang rusak dari biometrik citra sidik jari. Pada penelitian eksperimen ini, dipilih arsitektur *Pix2Pix GAN* untuk membangun pelatihan model jaringan saraf tiruan dengan melakukan perancangan dan implementasi. Kemudian akan dilanjutkan dengan evaluasi kualitas hasil pemulihan citra yang menggunakan metrik kuantitatif seperti *PSNR (Peak to Signal Noise Ratio)* dan juga menggunakan *SSIM (Structural Similarity Index Measure)*. Pada penelitian kali ini, pendekatan kuantitatif dipilih karena hasil dievaluasi secara subjektif berdasarkan angka-angka pengukuran dari *PSNR* dan *SSIM*.

3.2 Desain Eksperimen

Rancangan yang digunakan pada penelitian ini ialah menggunakan eksperimen terkontrol yang mana akan dilakukan secara sistematis dalam beberapa tahapan. Pada tahap pertama adalah dengan melakukan pengumpulan dataset, dimana dataset yang digunakan ialah *SOCOFing (SOKO Fingerprint Dataset)*. Dataset *SOCOFing* ini berisikan citra sidik jari dalam berbagai kategori diantaranya: asli (*original*), termodifikasi (*altered*), dan juga ditutupi (*masked*). Tahapan selanjutnya yang akan dilakukan ialah melakukan *preprocessing*, dimana pada tahapan ini citra akan diproses menjadi format yang sesuai dengan kebutuhan model, normalisasi citra ke rentang $[-1, 1]$, termasuk pemisahan input dan target, dan penyesuaian ukuran gambar ke 256 x 256 piksel.

Setelah *preprocessing* selesai dilakukan, tahap selanjutnya ialah implementasi model *Pix2Pix Generative Adversarial Network (GAN)* menggunakan *TensorFlow*. Model ini terdiri dari dua komponen utama yaitu: Generator dengan arsitektur *U-Net* dan juga *Discriminator* dengan pendekatan *PatchGAN*. Setelah itu, model akan dilatih sebanyak beberapa *epoch* hingga dirasa

cukup menggunakan data latih yang di dapat dari dataset SOCOFing. Setelah mendapatkan hasil dari proses pelatihan ini, proses selanjutnya hasilnya akan diuji menggunakan data uji, dan akan dievaluasi secara kuantitatif menggunakan metrik *PSNR (Peak to Signal Noise Ratio)* dan juga *SSIM (Structural Similarity Index Measure)*. Hasil evaluasi ini kemudian akan digunakan untuk menilai seberapa baik hasil restorasi dari generator jika dibandingkan dengan citra target (*ground truth*) atau citra asli.

3.3 Variabel Penelitian

Adapun beberapa jenis variabel yang berperan dalam penelitian ini. Variabel yang pertama ialah variabel bebas yang merupakan parameter yang diatur oleh peneliti, seperti halnya arsitektur model *Pix2Pix GAN*, jumlah *epoch* penelitian, dan juga *learning rate*. Variabel yang kedua ialah variabel terikat yang merupakan nilai-nilai keluaran yang menjadi hasil eksperimen, yaitu nilai *PSNR*, nilai *SSIM* dan metrik evaluasi lain yang akan dijelaskan dibawah, serta kualitas visual dari citra yang dihasilkan oleh model. Sedangkan untuk variabel yang ketiga ialah variabel kontrol yang merupakan komponen yang dijaga tetap nilainya, seperti jenis dataset (SOCOFing), ukuran gambar (256 x 256 piksel), serta teknik *preprocessing* yang digunakan.

3.4 Instrumen Penelitian

Dalam penelitian ini, instrumen yang digunakan terdiri dari beberapa perangkat antara lain: perangkat keras dan juga perangkat lunak. Untuk perangkat lunak yang digunakan dalam penelitian kali ini diantaranya ialah bahasa pemrograman python 3, pustaka *TensorFlow 2.x* sebagai *framework* utama untuk implementasi *deep learning*, serta pustaka *NumPy* dan *Matplotlib* untuk memanipulasi data dan visualisasi. Dalam pengerjaannya, proses pelatihan dan pengujian dalam penelitian kali ini dilakukan menggunakan *platform Google Colab* yang mendukung *GPU* untuk mempercepat proses komputasi. Dataset yang digunakan di dalam penelitian ini bersifat publik dan juga dapat diakses serta diunduh secara bebas dari internet, yakni dataset SOCOFing. Untuk evaluasi dalam

penilaian performa model, digunakanlah *PSNR*, *SSIM*, serta *Generator loss* dan *Discriminator loss* selama proses latihan dijalankan.

3.5 Alur Penelitian

Secara garis besar, alur penelitian ini terdiri 6 tahapan antara lain: (1) pengumpulan dataset, (2) *preprocessing* citra, (3) implementasi arsitektur *Pix2Pix GAN*, (4) pelatihan model, (5) pengujian model, (6) evaluasi hasil. Keenam tahapan tersebut akan dilakukan secara beruntun yang membentuk suatu proses untuk memastikan model dapat dilatih secara sistematis dan diuji secara akurat.

3.6 Teknik Evaluasi

Untuk mengukur performa model dalam menghasilkan suatu citra sidik jari dimana hasil citra sidik jari tersebut merupakan hasil restorasi yang mendekati citra asli, perlu dilakukanlah evaluasi. Dalam pelaksanaannya, teknik evaluasi yang digunakan memiliki dua metrik utama yakni *PSNR* dan *SSIM*. *PSNR* digunakan untuk mengukur persamaan dari nilai piksel antara citra asli dan citra hasil. Sedangkan untuk *SSIM* lebih digunakan untuk mengukur kemiripan struktur visual antar citra. Selain dari dua metrik diatas, nilai *generator loss* dan *discriminator loss* merupakan tolak ukur lain yang dicatat selama proses pelatihan sebagai indikator perkembangan pelatihan yang dilakukan oleh model selama proses pembelajaran. Sebagai penyempurnaan, akan ditambahkan metrik evaluasi lain diantaranya : *Contrastive Language-Image Pretraining for Image Quality Assessment (CLIP-IQA)* untuk melihat seberapa baik citra yang telah direkonstruksi dengan citra inputnya dari segi kualitas gambar (*blurred*) , *Learned Perceptual Image Patch Similarity (LPIPS)* untuk melihat dari subjektif manusia, *Edge Preservation Score (EPS)* untuk melihat seberapa banyak kontur atau detail penting pada citra sidik jari dipertahankan, dan juga *Edge Strength* yang berisi *Edge Input Strength* dan *Edge Output Strength* untuk melihat seberapa baik model meregenerasi dan mempertahankan kontur maupun struktur garis suatu citra saat proses rekonstruksi dilakukan.

3. 7 Kriteria Keberhasilan

Pada penelitian yang dilakukan kali ini, indikator agar bisa dinyatakan berhasil apabila model yang dilatih menghasilkan citra yang memiliki kualitas tinggi. Hal tersebut dapat ditunjukkan dengan nilai *PSNR* diatas 20db dan nilai dari *SSIM* mendekati 1 (satu) yang mana nilai tersebut menunjukkan bahwa citra yang dihasilkan generator tidak hanya mendekati citra asli secara numerik, namun juga mirip secara visual dan struktural. Selain dari dua indikator tersebut, ada juga indikator yang menunjukkan keberhasilan penelitian ini yakni nilai *generator loss* yang terus menurun stabil dan juga nilai *discriminator loss* yang tidak mendominasi terlalu besar. Indikator-indikator tersebut menunjukan bahwa proses latihan yang dijalankan model berjalan dengan baik dan model tidak mengalami *overfitting* maupun mode *collapse*. Selain menggunakan *PSNR* dan *SSIM*, pada penelitian ini juga akan menggunakan metrik evaluasi lain dimana bisa dikatakan berhasil apabila nilai dari *CLIP-IQA* antara nilai *output* naik dibandingkan nilai *input*. Sedangkan untuk nilai *LPIPS* dikatakan baik jika memiliki rentang 0.0 hingga 0.2 yang menandakan bahwa dari subjektif manusia atau persepsi manusia, dari dua citra tersebut mirip namun ada perbedaan di detail. Jika nilai *LPIPS* 0.0 maka tidak ada perbedaan sama sekali, sedangkan jika melebihi 0.2 hingga 0.4 maka terbilang bahwa citra sudah sangat berbeda dari sudut pandang persepsi manusia dibanding dengan acuan citra awalnya. Pada metrik evaluasi *EPS* agar bisa dikatakan memiliki hasil yang baik harus memiliki nilai mendekati 1, semakin tinggi nilainya semakin banyak kontur dan detail struktur yang dipertahankan selama proses rekonstruksi. Sedangkan untuk *Edge Input Streng* dan *Edge Output Strength* juga sama dengan *CLIP-IQA* dimana jika citra hasil lebih tinggi nilainya dibanding citra awal maka menjadi indikator model telah melakukan regenerasi pada *ridge* di citra sidik jari dan memiliki kontur garis lebih baik dari pada citra awal.

BAB IV

HASIL DAN ANALISIS PENELITIAN

4.1 Hasil

4.1.1 Jenis Penelitian

Pada penelitian yang dilakukan menggunakan jenis penelitian eksperimen kuantitatif. Jenis penelitian ini bertujuan untuk mengukur pengaruh dari sebab-akibat pada suatu variabel (disini menjelaskan bagaimana pengaruh dari citra yang direkonstruksi menggunakan model *Pix2Pix GAN*) secara terstruktur, sistematis, dan tentunya didasarkan pada data numerik menggunakan beberapa metrik evaluasi untuk mengetahui pengaruhnya. Pada penelitian ini hasil yang akan didapatkan ialah berupa data angka atau skor yang akan disajikan secara statistik dan kemudian akan dilakukan penilaian atau analisa evaluasi untuk menarik suatu kesimpulan.

4.1.2 Pengumpulan dataset

Dataset yang digunakan dalam penelitian ini ialah menggunakan dataset *open-source* yang dapat diakses secara mudah oleh siapapun dan dimanapun melalui sarana internet. SOCOFing merupakan salah satu dataset *open-source* yang bisa diakses yang menyediakan citra sidik jari dari 600 partisipan dengan pasangan citra asli dan rusak didalamnya. Pada Dataset SOCOFing ini terdapat kurang lebih 55.000 data yang disajikan dimana memiliki 3 jenis manipulasi kerusakan di dalamnya sebagai representasi kerusakan *real* yang sering terjadi di dunia nyata. Manipulasi kerusakan yang dilakukan ialah diantaranya: *Central Rotation* (rotasi bagian tengah pola garis), *Obliteration* (kerusakan sebagian pola garis), dan juga *Z-Cut* (pemotongan garis yang dilakukan secara diagonal) seperti yang bisa terlihat pada Gambar 4. 1 dibawah.



Gambar 4. 1 Manipulasi Kerusakan Dataset

Manipulasi yang tertera pada Gambar 4. 1 diatas tidak dilakukan oleh peneliti, namun memang sudah tersedia dan disajikan langsung oleh dataset SOCOFing yang digunakan. Karena hal itulah dataset SOCOFing ini dipilih pada penelitian kali ini. Pada penelitian kali ini digunakan 3.000 data dalam proses pelatihan modelnya dengan 5 data testing diluar data pelatihan.

4.1.3 Preprocessing Data

Data yang digunakan pada dataset SOCOFing harus diolah terlebih dahulu seperti digabungkan dan juga dijadikan ukuran 256x256 piksel agar data dapat diolah untuk melakukan pelatihan model. Alasannya ialah agar seimbang antara kualitas dan juga efisiensi proses komputasi dimana ukuran 256x256 piksel cukup besar untuk menangkap detail yang terdapat pada citra sidik jari, namun dapat cepat diproses secara cepat oleh *GPU* karena ukurannya kecil.

Pada tahap ini, citra akan dilakukan beberapa proses sebelum benar benar dilakukan *training* diantaranya citra akan dibaca dan kemudian akan dilakukan *split* untuk menghasilkan gabungan citra rusak dan citra asli atau target dan akhirnya akan dinormalisasikan ke $[-1, 1]$. Setelahnya citra akan dapat digunakan untuk proses pelatihan model. Secara lengkapnya sebelum digunakan, data akan dibaca dan dimasukkan ke *variabel image* berupa file mentah, kemudian akan diproses sebagai angka dan akan dianggap memiliki tiga lapisan (*RGB*) serta akan dipisahkan menjadi 2. Pemisahan ini akan menempatkan citra sidik jari *altered*/rusak pada sisi kiri sebagai *input* dan citra sidik jari *original*/asli akan ditempatkan pada sisi kanan sebagai *output*. Setelahnya 2 citra (*input & output*) akan diubah datanya dari integer (0-255) menjadi bilangan pecahan agar bisa

dihitung secara akurat dan dibagi menjadi 127,5 serta dikurangi satu untuk melakukan normalisasi mendekati 0 $[-1, 1]$ yang akan disimpan pada fungsi *load_image*.

Fungsi *load_dataset* didefinisikan yang mana berisi fungsi untuk mencari semua file dataset yang memiliki format .BMP dan setelahnya diacak. Setelah pengacakan data akan dimasukkan pada fungsi *load_image* yang telah dijelaskan sebelumnya. Hasil akhir dari proses ini ialah berupa sekumpulan dataset yang berupa pasangan *input-output* yang sudah rapi serta siap untuk dipakai pada proses pelatihan selanjutnya.

4.1.4 Modeling


Pada tahapan modeling atau biasa dikenal dengan tahapan pemodelan, akan dilakukan proses untuk melatih model *Deep Learning Pix2Pix GAN* yang akan digunakan untuk melakukan rekonstruksi pada citra sidik jari sebagai upaya penguatan sistem biometrik dan forensik digital. Pada tahapan ini, data yang berupa citra sidik jari gabungan yang telah melalui tahapan *preprocessing* akan dijalankan pada arsitektur model *Pix2Pix GAN* yang mana alur kerjanya dapat terlihat pada Gambar 2. 9 sebelumnya mengenai alur dari pemodelan *Pix2Pix GAN*.

Pada pelatihan ini model akan dijalankan pertama kali di Generator yang berupa U-Net dan akhirnya akan menghasilkan citra prediksi (rekonstruksi) dari citra yang rusak. Setelahnya citra rekonstruksi tadi akan dikirim ke *Discriminator* untuk dinilai apakah asli atau palsu dibandingkan dengan gambar aslinya seperti yang telah dijelaskan pada dasar teori diatas.

4.1.5 Data Keluaran


Pada penelitian ini, sangat disarankan untuk menggunakan data testing dengan jenis manipulasi kerusakan *Obliteration* atau dengan kata lain kerusakan pada sebagian pola garis suatu citra. pada dataset SOCOFing, jenis gambar dengan manipulasi kerusakan *Obliteration* ini memiliki format dengan nama belakang “_obl.BMP”. Jenis manipulasi kerusakan tersebut dipilih karena kerusakannya sangat merepresentasikan gangguan forensik di dunia nyata khususnya di Indonesia dimana citra sidik jari yang merupakan alat bukti sering terkena noda darah atau terkena air yang menyebabkan citra sidik jari mengalami kerusakan sebagian pola

garis seperti yang tergambar di jenis manipulasi kerusakan *Obliteration*. Untuk proses pelatihan model akan digunakan 3 jenis manipulasi kerusakan untuk memberikan variasi yang beragam agar model dapat belajar lebih efisien dan juga untuk menghindari *Overfitting* yang mana model *Pix2Pix GAN* terlalu menghafal data pelatihannya. Berikut merupakan tampilan dari kelima data tes yang telah dilakukan pada model 40, model 100, model 120, dan juga model 160.



Gambar 4. 2 Input 1 Testing


Gambar 4. 2 diatas menunjukkan hasil rekonstruksi pada *input* satu yang diambil dari dataset SOCOFing. *Input* 1 merupakan dataset yang memang dikhususkan untuk melakukan testing dan tidak digunakan dalam proses pelatihan model. Dapat dilihat saat *input* 1 dijalankan untuk dilakukan rekonstruksi pada model 40 citra sidik jari yang memiliki kerusakan di dalamnya sudah mulai dilakukan rekonstruksi garis sidik jarinya. Pada model 100 hingga 200 terlihat bahwa rekonstruksi yang dilakukan pada citra input 1 semakin baik terutama dalam meregenerasi garis dan mempertahankan kontur sidik jari agar tidak mengubah pola sidik jari.



Gambar 4. 3 Input 2 Testing


Gambar 4. 3 diatas menunjukkan hasil rekonstruksi pada *input* satu yang diambil dari dataset SOCOFing. *Input* 2 merupakan dataset yang memang dikhususkan untuk melakukan testing dan tidak digunakan dalam proses pelatihan model. Dapat dilihat saat *input* 2 dijalankan untuk dilakukan rekonstruksi pada model 40 citra sidik jari yang memiliki kerusakan di dalamnya sudah mulai dilakukan rekonstruksi garis sidik jarinya meskipun kurang sempurna. Pada model

100 hingga 200 terlihat bahwa rekonstruksi yang dilakukan pada citra *input* 2 semakin baik terutama dalam meregenerasi garis dan merapikan struktur garis menjadi lebih terlihat beraturan serta ketajaman garis serta mempertahankan kontur sidik jari agar tidak mengubah pola sidik jari.



Gambar 4. 4 *Input* 3 Testing

Gambar 4. 4 diatas menunjukkan hasil rekonstruksi pada *input* satu yang diambil dari dataset SOCOFing. *Input* 3 merupakan dataset yang memang dikhususkan untuk melakukan testing dan tidak digunakan dalam proses pelatihan model. Dapat dilihat saat *input* 3 dijalankan untuk dilakukan rekonstruksi pada model 40 citra sidik jari yang memiliki kerusakan di dalamnya sudah mulai dilakukan rekonstruksi garis sidik jarinya meskipun masih memiliki sedikit kecacatan dimana kerusakannya masih terdapat beberapa pada beberapa titik. Pada model 100 hingga 200 terlihat bahwa rekonstruksi yang dilakukan pada citra *input* 3 semakin baik terutama dalam meregenerasi garis dan mempertahankan kontur sidik jari agar tidak mengubah pola sidik jari. Secara subjektif dapat terlihat pada model 160, hasil rekonstruksi yang ditampilkan memiliki kualitas garis yang tajam dan kerusakan pada beberapa titik sebelumnya sudah tersama dan mulai membentuk *ridge* sidik jari.



Gambar 4. 5 *Input* 4 Testing

Gambar 4. 5 diatas menunjukkan hasil rekonstruksi pada *input* satu yang diambil dari dataset SOCOFing. *Input* 4 merupakan dataset yang memang dikhususkan untuk melakukan testing dan tidak digunakan dalam proses pelatihan model. Pada testing yang dilakukan dengan memasukkan objek tes keempat ini

terlihat bahwa kerusakan yang dimilikinya termasuk dalam kerusakan yang lumayan parah dimana hampir setengah dari sidik jari mengalami kerusakan berbeda dengan objek tes pertama hingga ketiga diatas. Hal tersebut dimaksudkan untuk melihat seberapa baik model belajar. Dapat dilihat saat *input* 4 dijalankan untuk dilakukan rekonstruksi pada model 40 citra sidik jari yang memiliki kerusakan di dalamnya sudah mulai dilakukan rekonstruksi garis sidik jarinya dan masih terlihat ada lubang dan garis sidik jari masih belum bisa tersambung sepenuhnya. Pada model 100 hingga 200 terlihat bahwa rekonstruksi yang dilakukan pada citra *input* 4 semakin baik terutama dalam meregenerasi garisnya meskipun belum sempurna dan kurang rapi namun sudah menggambarkan prediksi alur garis lebih terstruktur dan mulai tersambung satu sama lain serta mempertahankan kontur sidik jari agar tidak mengubah pola sidik jari.



Gambar 4. 6 *Input* 5 Testing

Gambar 4. 6 diatas menunjukkan hasil rekonstruksi pada *input* satu yang diambil dari dataset SOCOFing. *Input* 5 merupakan dataset yang memang dikhususkan untuk melakukan testing dan tidak digunakan dalam proses pelatihan model. Pada testing terakhir ini data yang digunakan untuk mengecek sengaja dipilih dengan kerusakan lebih dari 50% bahkan hampir bisa dibilang citra sidik jari pada objek tes ke-5 ini mengalami kerusakan hampir pada seluruh citra sidik jari dan memiliki kerusakan yang jenisnya menutupi garis dan kontur penting pada pola sidik jari. Saat dilakukan rekonstruksi dapat dilihat saat *input* 5 dijalankan pada model 40 citra sidik jari yang memiliki kerusakan di dalamnya sudah mulai dilakukan rekonstruksi garis sidik jarinya dengan beberapa area masih terlihat kosong (dalam artian garis sidik jari belum tersambung) serta pada bagian gelap yang terlihat menutup area yang cukup besar sudah terlihat lumayan tersamar dan mulai sedikit menampilkan garis samar. Pada model 100 hingga 200 terlihat bahwa rekonstruksi yang dilakukan pada citra *input* 5 semakin baik terutama dalam

meregenerasi garis untuk mengisi bagian kosong sebelumnya dan bagian gelap yang sebelumnya menutupi sudah tidak lagi tersamar namun juga sudah dilakukan perbaikan dimana garis yang sebelumnya sama sudah mulai terlihat membentuk sidik jari secara utuh dan menampilkan pola sidik jari yang lengkap serta model dapat mempertahankan kontur sidik jari agar tidak mengubah pola sidik jari.

4.2 Analisis Penelitian

4.2.1 Evaluasi Pelatihan


Saat melakukan proses modeling *Pix2Pix GAN* selesai dilakukan, langkah selanjutnya adalah evaluasi dari proses pelatihan untuk mengetahui seberapa baik kinerja model dalam merekonstruksi sidik jari. Dalam penilaian kali ini akan digunakan beberapa metrik evaluasi seperti yang telah dijelaskan di dasar teori diantaranya terdapat *PSNR*, *SSIM*, *Generator Loss*, dan juga *Discriminator Loss*.

Tabel 4. 1 Evaluasi *Epoch* Pelatihan

Epoch	Gen Loss	Disc Loss	PSNR	SSIM
1	6,2633	1,2214	21,64	0,9241
10	3,3572	1,2309	26,14	0,9614
20	2,7732	1,274	28,79	0,9712
30	2,7376	1,2087	29,83	0,9748
40	3,597	0,8602	29,13	0,9711
50	5,7354	0,3751	26,87	0,9617
60	4,4132	0,7461	28,31	0,966
70	4,4908	0,7535	28,29	0,9654
80	4,499	0,7509	28,32	0,9651
90	4,5005	0,7717	28,36	0,9652
100	4,7618	0,6963	28,38	0,9652
110	4,6097	0,736	28,5	0,9659
120	4,7233	0,699	28,56	0,9662
130	5,9322	0,4969	27,89	0,9625
140	5,7995	0,4608	28,08	0,9629
150	5,4605	0,4769	28,92	0,9678
160	5,7488	0,4936	28,97	0,9673
170	7,9884	0,3306	28,2	0,9516
180	7,8085	0,2062	27,21	0,9522
190	6,884	0,2879	29,74	0,9689
200	8,3794	0,2149	27,8	0,9565


Pada Tabel 4.1 terlihat terdapat sejumlah empat metrik evaluasi yang digunakan diantaranya ada *generator loss*, *discriminator loss*, *PSNR*, dan *SSIM*. Dari 200 epoch nilai *generator loss* terbaik berada di titik 30, untuk nilai terbaik *discriminator loss* berada di titik 20, sedangkan untuk *PSNR* dan *SSIM* memiliki nilai terbaik pada titik yang sama yaitu 30. Hal tersebut menunjukkan bahwa model memiliki awal yang cukup bagus yang mengindikasikan kinerja awal model yang baik. Terlihat *Generator Loss* dari 6,2 mulai menurun perlahan yang menunjukkan bahwa Generator mulai belajar untuk melakukan rekonstruksi. Hingga pada titik 40 menunjukkan generator loss mengalami peningkatan hingga pada poin ke 120, hal tersebut mengindikasikan bahwasannya mulai terlihat persaingan antara generator dengan *discriminator*. Hal tersebut wajar terjadi dan masih dalam batas terkontrol. Pada poin ke 50 generator mencoba untuk berusaha lebih keras untuk mengelabui *discriminator* yang mana membuahkan hasil yang bisa dibilang memuaskan dimana nilai dari *generator loss* di tahap ini mulai stabil.

Begitu pula dengan *Discriminator Loss* yang menunjukkan nilai stabil dan perlahan lahan belajar serta bersaing dengan generator. Hal tersebut merupakan kabar baik dimana *generator loss* dan juga *discriminator loss* mulai menurun dan saling bersaing satu sama lain. Persaingan yang kompetitif akan menghasilkan hasil *output* rekonstruksi menjadi lebih baik kualitasnya. Sangat terlihat dari Gambar 4. 7 dibawah menunjukkan bahwa grafik dari nilai *discriminator loss* mulai menurun secara perlahan dengan stabil meskipun terdapat beberapa saat *discriminator* sangat bekerja keras untuk menilai hasil dari generator, namun *discriminator* tetap stabil perlahan menurun.




Gambar 4. 7 Grafik Gen loss & Disc loss

Melihat grafik yang tertera pada Gambar 4. 8 diatas sementara dapat disimpulkan terdapat lonjakan pada titik 40, 100, dan 160 keatas. Hal tersebut akan dievaluasi lebih lanjut dari testing dengan 5 data tes yang akan dilakukan selanjutnya dengan mempertimbangkan dua metrik evaluasi lainnya yaitu *PSNR* dan *SSIM*. Untuk nilai dari *SSIM* menunjukkan progres yang sangat bagus dimana nilainya semakin lama semakin naik secara perlahan. Hal tersebut menjadikannya indikator utama pada rekonstruksi sidik jari dimana hampir seluruh struktur lokal dipertahankan saat generator melakukan rekonstruksi pada sidik jari. Dari gambar 4. 8 dibawah yang menyajikan grafik *SSIM* terlihat bahwa *SSIM* dengan penurunan nilai berada di titik 40 dan setelahnya *SSIM* menampilkan nilai yang stabil dan tidak terdapat lonjakan naik maupun turun hingga di titik 160. Pada titik 160 keatas menunjukkan nilai *SSIM* yang lonjakannya turun kemudian naik dan setelah titik 190 mulai turun kembali dititik 200. Hal tersebut yang nantinya akan dievaluasi lebih lanjut menggunakan *CLIP-IQA* dipembahasan selanjutnya.



Gambar 4. 8 Grafik SSIM

Tidak berbeda dengan *SSIM*, *PSNR* juga menunjukkan nilai yang perlahan meningkat yang dapat dilihat pada Gambar 4. 9 dibawah yang menyajikan grafik dari nilai *PSNR* mulai dari titik awal pelatihan hingga akhir. Perbedaan dari *PSNR* dan *SSIM* disini ialah nilai *PSNR* dari awal hingga akhir memiliki kestabilan hingga di akhir proses pelatihan yaitu di titik 200 namun keseimbangan antara *PSNR* dan *SSIM* masih tetap terjaga. Nilai *PSNR* yang perlahan naik dan terus stabil hingga akhir ini menandakan bahwa *Output* yang dihasilkan oleh generator dalam melakukan rekonstruksi sidik jari ini memiliki kualitas piksel yang bersih dan jernih menyerupai *ground truth* atau citra sidik jari asli.



Gambar 4. 9 Grafik PSNR

Dari data dan grafik yang telah disajikan diatas, terlihat bahwa terdapat beberapa titik yang perlu dilakukan evaluasi lebih lanjut pada saat melakukan pengecekan model atau proses tes. Pada penelitian ini peneliti mengambil beberapa titik untuk dilakukan tes agar dapat melihat model terbaik yang dapat digunakan

dengan hasil yang paling memuaskan titik-titik model yang akan diambil ialah pada titik 40 dengan pertimbangan bahwa di titik ini menunjukkan awal kinerja model yang baik dan terdapat awal lonjakan dari nilai *gen loss* dan juga *disc loss* namun memiliki nilai *PSNR* dan *SSIM* yang terbilang tinggi.

Adapun titik 100 yang merupakan lonjakan kedua yang terjadi setelah sebelumnya terjadi lonjakan di titik 40 meskipun setelahnya generator mulai berusaha keras untuk belajar. Pengambilan titik 100 ini didasari meskipun terjadi lonjakan, titik 100 merupakan titik tengah pada keseluruhan proses pelatihan ini dan dianggap model sudah belajar dan diharapkan menampilkan hasil yang baik. Selain titik 100, peneliti juga mengambil titik 120 untuk evaluasi lebih lanjut dengan mempertimbangkan adanya lonjakan yang tidak konsisten dari *generator loss* namun masih tetap seimbang dengan *discriminator loss*.

Selain itu, titik 160 juga ikut dipertimbangkan melihat memiliki rerata nilai *gen loss* dan *disc loss* serta *PSNR* dan *SSIM* yang dinilai berpotensi untuk menghasilkan model dengan kualitas tertinggi atau mencapai kualitas puncak sebelum terjadi lonjakan yang tak beraturan setelahnya. Sedangkan untuk titik 200 akan dijadikan perbandingan evaluasi dengan pertimbangan beberapa model sebelumnya yang telah dipilih dengan melihat bahwa titik 200 merupakan titik akhir proses pelatihan yang diharapkan dapat menghasilkan citra rekonstruksi sidik jari yang memiliki kualitas tertinggi meskipun dengan lonjakan *gen loss* dan *disc loss* pada prosesnya serta penurunan nilai *PSNR* dan *SSIM*.

4.2.2 Evaluasi Keberhasilan

Pada penjelasan sebelumnya membahas mengenai evaluasi pelatihan dimana muncul nilai *gen loss*, *disc loss*, *PSNR*, dan *SSIM*. Hasil analisa dari evaluasi pelatihan ialah model *Pix2Pix GAN* dapat dipastikan melakukan pembelajaran dengan sistem persaingan atau biasa yang kita kenal dengan *Adversarial*. Dan persaingan tersebut tergambar dengan jelas pada *gen loss* dan *disc loss* diatas. Selain menggunakan evaluasi tersebut, dibutuhkan evaluasi lain untuk melihat tingkat keberhasilan pembelajaran model ini dan dipilihlah metrik evaluasi diantaranya terdapat: *CLIP-IQA*, *LPIPS*, *Edge Preservation Score*, dan (*Edge Input Strength & Edge Output Strength*). Hal tersebut bertujuan untuk melihat seberapa

baik model melakukan rekonstruksi pada citra dengan dataset testing yang memang telah disiapkan dari awal di luar data pelatihan. Ada terdapat sejumlah 5 (lima) data yang akan tes pada model 40, model 100, model 120, model 160, dan juga model 200 seperti yang telah dijelaskan diatas mengapa mengambil mode pada 5 (lima) titik tersebut.

Pada pengecekan (test) yang akan dilakukan ini, data tes akan dimasukan secara bertahap (satu per satu) untuk bisa melihat nilai evaluasinya yang mana proses ini dilakukan pada *gradio* untuk membuat sebuah *User Interface* suatu web tanpa harus membuatnya dari 0 untuk menjalankan model *machine learning* maupun *deep learning*. Berikut Tabel 4. 2 dibawah yang menyajikan data mengenai evaluasi pada hasil rekonstruksi pada data *input* berjumlah 5 (lima) pada setiap model yang telah dipilih untuk dilakukan evaluasi.


Tabel 4. 2 Evaluasi Model 40

Nama Gambar	CLIP-IQA (Input)	CLIP-IQA (Output)	LPIPS	EPS	ES (Input)	ES (Output)
Gb 1- 40	0,6553	0,6801	0,0603	0,7051	0,1172	0,1523
Gb 1-100	0,6553	0,6901	0,0533	0,9589	0,1172	0,1311
Gb 1-120	0,6553	0,6196	0,0562	0,9544	0,1172	0,1317
Gb 1-160	0,6553	0,6533	0,0551	0,9635	0,1172	0,1296
Gb 1-200	0,6553	0,5561	0,0991	0,8696	0,1172	0,15

Dari data *input* (test) yang pertama ini dimana merupakan citra yang dipilih dengan tingkat kerusakan paling rendah. Nilai CLIP-IQA pada model 40 dan juga model 100 meningkat yang mana hal tersebut menunjukkan bahwa hasil dari rekonstruksi 2 model tersebut (40 & 100) memiliki hasil yang lebih jernih dibanding *inputnya*, berbanding terbalik dengan model lainnya yang malah menurun namun dari model yang nilai CLIP-IQA nya menurun ternyata hanya model 160 yang memiliki penurunan sangat kecil dibanding dua lainnya yang artinya kualitas dari hasil rekonstruksi yang dilakukan menggunakan model 160 memiliki citra yang sama jernihnya dengan input.

Nilai LPIPS yang muncul tertera dengan nilai dibawah atau mendekati nilai 0.1 yang menandakan bahwa citra hasil rekonstruksi bisa dikatakan masih cukup mirip dengan citra *inputnya* dinilai dari sudut pandang persepsi manusia. Dan hal

tersebut merupakan kabar bagus yang menandakan bahwa model berhasil melakukan rekonstruksi dengan mempertahankan citra sidik jari rusak tanpa mengubahnya secara ekstrim secara subjektif manusia. Pada nilai *Edge Preservation Score* menunjukkan bahwa nilainya mendekati nilai 1 terkecuali model 40 dan model 200 yang nilainya lebih rendah dibanding tiga model lainnya seperti yang terlihat pada Gambar 4. 10 yang menyajikan grafik dari Tabel 4. 2 diatas. Peningkatan maupun penurunan nilai *Edge Preservation Score* merupakan sesuatu yang harus benar benar diperhatikan karena hal tersebut menandakan bahwa model dapat melakukan rekonstruksi dengan mempertahankan kontur lokal dan detail struktur yang terdapat pada sidik jari yang mana untuk sidik jari kontur dan detail struktur sangat penting. Sedangkan untuk *Edge Strength* terlihat bahwa di semua model sudah menampilkan hasil yang memuaskan dimana *outputnya* lebih tinggi dibandingkan dengan *inputnya*. Kenaikan nilai tersebut berarti model sudah paham bagaimana cara menghasilkan garis yang lebih tajam.



Gambar 4. 10 Grafik *Input* Tes 1

Dari Evaluasi diatas dengan melakukan rekonstruksi *input* tes 1 pada beberapa model yang dipilih, dapat disimpulkan bahwa model 160 memiliki kualitas yang lebih tinggi dibandingkan dengan model lainnya baik dilihat dari nilai CLIP-IQA yang tidak terlalu menurun, memiliki nilai LPIPS yang mengindikasikan bahwa secara subjektif manusia hasil rekonstruksi sama dengan *inputnya*, dan juga

menampilkan nilai *Edge Preservation Score* tertinggi yang mana mengindikasikan bahwa banyak kontur krusial pada citra sidik jari yang masih dipertahankan serta memiliki nilai *Edge Strength* yang meningkat dimana kekuatan garisnya lebih tajam dibandingkan *inputnya*.


Tabel 4. 3 Evaluasi *Input* Tes 2

Nama Gambar	CLIP-IQA (Input)	CLIP-IQA (Output)	LPIPS	EPS	ES (Input)	ES (Output)
Gb 2- 40	0,4688	0,5871	0,1159	0,7521	0,1176	0,1494
Gb 2-100	0,4688	0,5013	0,1295	0,9447	0,1176	0,1377
Gb 2-120	0,4688	0,3917	0,1196	0,943	0,1176	0,139
Gb 2-160	0,4688	0,5005	0,1096	0,9573	0,1176	0,1332
Gb 2-200	0,4688	0,3183	0,1314	0,8926	0,1176	0,1448

Tabel 4. 3 diatas menyajikan data evaluasi untuk citra *input* tes kedua yang dilakukan rekonstruksi pada beberapa model yang telah dipilih sebelumnya. Berbeda dengan *input* tes yang pertama, citra *input* tes yang kedua memiliki kerusakan yang lebih tinggi levelnya dibanding dengan yang pertama untuk melihat seberapa baik model dapat melakukan rekonstruksi pada citra dengan level kerusakan yang berbeda. Metrik evaluasi pertama ialah CLIP-IQA menunjukkan kenaikan nilai pada model yang telah dipilih terkecuali model 120 dan juga model 200 yang mengalami penurunan nilai yang cukup tinggi dimana penurunan nilai tersebut mengindikasikan bahwa hasil rekonstruksi memiliki kualitas citra yang lebih buruk dibandingkan dengan *inputnya* secara kejernihan. Pada *input* tes yang kedua terlihat bahwa nilai CLIP-IQA pada model 160 menunjukkan peningkatan dengan input yang lebih tinggi level kerusakannya.

Nilai *LPIPS* yang terlihat pada data diatas menunjukkan nilai pada rentang 0,1 yang menandakan bahwa hasil rekonstruksi yang dilakukan tiap-tiap model dapat dikatakan cukup mirip dengan *inputnya* jika dilihat dari sudut pandang persepsi manusia. Namun jika diamati, model 160 menunjukkan nilai *LPIPS* yang paling rendah dibandingkan model lainnya yang mengindikasikan bahwa secara tampilan dari subjektif manusia, hasil rekonstruksinya lebih mirip dibandingkan model lainnya jika dibandingkan dengan *inputnya*. Pada praktiknya di *input* kedua ini level kerusakan lebih tinggi dari *input* sebelumnya dan ternyata model 160

memiliki nilai *LPIPS* paling rendah yang mana mengartikan paling mirip dengan *input*nya, namun jika kita telaah lebih lanjut ternyata pada model 160 ini memiliki nilai *Edge Preservation Score* paling tinggi dibandingkan dengan model-model lainnya serta memiliki kekuatan garis yang tinggi namun tidak berlebihan. Hal tersebut menjadi poin plus dimana model belajar secara perlahan dan tidak berlebihan namun terdapat progres yang pasti. Kesimpulan dari evaluasi *input* tes kedua ini tetaplah model 160 yang memiliki kualifikasi paling tinggi dibandingkan dengan model lainnya dilihat dari nilai *CLIP-IQA* yang naik dan juga memiliki nilai *LPIPS* yang tidak berlebihan serta memiliki nilai *Edge Preservation Score* yang paling tinggi yang dapat dilihat pada Gambar 4. 11 dibawah yang menyajikan grafik evaluasi pada *input* kedua ini sebagai indikasi dapat mempertahankan kontur dan detail struktur paling banyak dibandingkan model lain dan memiliki kekuatan garis yang tidak berlebihan namun tetap ada peningkatan. Nilai-nilai plus tersebut yang menjadikan model 160 memiliki kualifikasi model dengan performa puncak yang sempurna dari pelatihan model ini.




Gambar 4. 11 Grafik Evaluasi *Input* Tes 2

Tabel 4. 4 dibawah menyajikan data dari evaluasi model *Pix2Pix GAN* pada beberapa model yang telah dipilih sebelumnya menggunakan *input* test ke-tiga yang merupakan data sidik jari dengan level atau tingkatan yang berbeda dibanding dengan 2 *input* test sebelumnya untuk menguji seberapa baik kinerja model dalam

melakukan rekonstruksi citra sidik jari yang rusak. Metrik evaluasi yang digunakan untuk mengukurnya pun sama dengan *input* yang sebelumnya yakni menggunakan *CLIP-IQA*, *LPIPS*, *Edge Preservation Score*, dan juga *Edge Strength*. Pada kasus percobaan menggunakan data tes yang ke-3 ini didapatkan hasil yang mengalami penurunan nilai metrik evaluasi pada setiap modelnya tanpa terkecuali. Namun hal tersebut tidak menjadikan model yang telah dilatih tidak memiliki kualifikasi dalam melakukan rekonstruksi citra sidik jari. Jika diamati dengan seksama, nilai-nilainya memiliki penurunan dengan kisaran yang relatif kecil dimana masih termasuk kedalam kategori stabil serta dampak yang akan terjadi tidak akan signifikan.

Tabel 4. 4 Evaluasi *Input* Tes 3

Nama Gambar	CLIP-IQA (Input)	CLIP-IQA (Output)	LPIPS	EPS	ES (Input)	ES (Output)
Gb 3- 40	0,6937	0,5763	0,0633	0,7124	0,1232	0,157
Gb 3-100	0,6937	0,6657	0,0632	0,9537	0,1232	0,1391
Gb 3-120	0,6937	0,5549	0,0634	0,9476	0,1232	0,1412
Gb 3-160	0,6937	0,6496	0,0597	0,9605	0,1232	0,1364
Gb 3-200	0,6937	0,4319	0,0845	0,8916	0,1232	0,1511



Gambar 4. 12 Grafik Evaluasi *Input* Tes 3

Pada Gambar 4. 12 diatas juga menyajikan grafik evaluasi model yang telah dipilih menggunakan data test ke-3. Grafik tersebut menunjukkan secara nyata


terdapat penurunan meskipun bukan lonjakan penurunan melainkan penurunan yang relatif kecil dan masih dalam kategori tidak ada dampak yang signifikan pada citra hasilnya. Untuk menilai secara keseluruhan pada tes ke-3 ini, dilakukan pengambilan data yang tidak memiliki nilai kenaikan atau penurunan yaitu akan dinilai menggunakan *LPIPS* untuk melihat seberapa mirip kualitas hasil rekonstruksi dengan citra *input* nya dari subjektif manusia serta menggunakan nilai metrik evaluasi *Edge Preservation Score* untuk melihat berapa banyak kontur atau detail struktur yang dipertahankan selama proses rekonstruksi. Nilai *LPIPS* dari kelima model tersebut yang memiliki nilai terendah ialah model 160 dan juga model 100 dimana dua model tersebut memiliki nilai terendah yang mengindikasikan bahwa hasil rekonstruksi memiliki kemiripan dengan citra *input*nya. Untuk nilai *Edge Preservation Score* merupakan termasuk pada dua tertinggi yang hampir mendekati nilai 1 yang menunjukkan bahwa hasil rekonstruksi model mempertahankan hampir seluruh kontur penting atau detail struktur pada citra *input*nya. Kesimpulannya disini tetap memilih model 160 dengan pertimbangan dua nilai evaluasi (*LPIPS* dan *Edge Preservation Score*) dimana nilai *LPIPS* lebih rendah karena jika melakukan rekonstruksi dengan objek sidik jari, jika terdapat banyak perubahan akan meningkatkan probabilitas perubahan identitas juga. Hal tersebut didukung dengan nilai *Edge Preservation Score* yang memiliki nilai yang lebih tinggi dibanding model 100.

Tabel 4. 5 Evaluasi *Input* Tes 4

Nama Gambar	CLIP-IQA (Input)	CLIP-IQA (Output)	LPIPS	EPS	ES (Input)	ES (Output)
Gb 4- 40	0,4509	0,5021	0,1589	0,7052	0,0737	0,1151
Gb 4-100	0,4509	0,476	0,1989	0,8388	0,0737	0,1103
Gb 4-120	0,4509	0,5829	0,1997	0,811	0,0737	0,1148
Gb 4-160	0,4509	0,539	0,1907	0,8441	0,0737	0,1083
Gb 4-200	0,4509	0,3692	0,2543	0,7125	0,0737	0,1338

Pada evaluasi *input* test keempat masih akan sama dinilai dengan metrik evaluasi sebelumnya guna melihat seberapa jauh kinerja model dalam melakukan rekonstruksi citra sidik jari yang rusak menggunakan model *Pix2Pix GAN*. Tabel 4. 5 diatas menyajikan data evaluasi setelah data tes dijalankan model terpilih. Data

tes ke 4 merupakan data tes dengan kerusakan yang lebih ekstrim dibandingkan 3 data tes sebelumnya dimana hampir setengah area sidik jari tertutupi oleh kerusakan. Nilai *CLIP-IQA* menampilkan bahwasanya setiap model mengalami peningkatan yang relatif kecil dan stabil. Dimana hal tersebut menunjukkan bahwa dengan citra dari data test dengan kerusakan cukup ekstrim, model melakukan rekonstruksi dengan melakukan perbaikan citra dimana hasil rekonstruksi menjadi semakin jernih. Nilai *LPIPS* juga menunjukkan pada kisaran angka 0,1 hingga 0,2 yang mana hal tersebut mengindikasikan bahwa hasil rekonstruksi dari tiap-tiap model memiliki citra yang bisa dikatakan hampir mirip dengan citra *inputnya* dinilai dari sudut pandang persepsi manusia. Hal tersebut menandakan bahwa kerusakan yang menutupi setengah citra sidik jari berhasil dihilangkan. Namun dengan syarat kontur penting atau detail struktur penting yang terdapat pada sidik jari harus tetap dipertahankan agar tidak mengubah identitas si pemilik sidik jari. Nilai *Edge Preservation Score* menunjukkan nilai pada rentang $0,8 > x$ hingga $x > 0,8$ seperti yang terlihat pada Gambar 4. 13 yang menunjukkan grafik dari evaluasi pada data test 4 yang dijalankan pada masing-masing model. Agar syarat awal terpenuhi maka akan diambil yang memiliki rentang $x > 0,8$ yang artinya lebih dari 80% kontur penting atau detail struktur pada sidik jari dipertahankan selama proses rekonstruksi.




Gambar 4. 13 Grafik Evaluasi Input 4

Dari kelima data yang dilakukan pengetesan ini, hanya model 100, model 120, dan juga model 160 saja yang memasuki kualifikasi. Dari ketiga model tersebut akan dicari kembali mana model yang memiliki nilai *Edge Preservation Score* paling tinggi, karena disini kita menginginkan hasil rekonstruksinya tidak mengubah informasi atau bahkan merusaknya. Kesimpulan yang bisa ditarik pada evaluasi test menggunakan data test keempat ini ialah model yang paling berkualifikasi memiliki performa tertinggi dalam melakukan rekonstruksi sidik jari ialah model 160 karena memiliki nilai *Edge Preservation Score* tertinggi diangka 0,8441 yang menunjukkan bahwa sekitar 84% kontur penting yang terdapat pada sidik jari dapat dipertahankan selama proses rekonstruksi.

Tabel 4. 6 Evaluasi *Input* Tes 5

Nama Gambar	CLIP-IQA (Input)	CLIP-IQA (Output)	LPIPS	EPS	ES (Input)	ES (Output)
Gb 5- 40	0,5199	0,5324	0,1852	0,692	0,0718	0,1158
Gb 5-100	0,5199	0,5402	0,236	0,8326	0,0718	0,1186
Gb 5-120	0,5199	0,5058	0,2334	0,8129	0,0718	0,119
Gb 5-160	0,5199	0,6282	0,2403	0,8435	0,0718	0,1159
Gb 5-200	0,5199	0,3884	0,2462	0,7474	0,0718	0,1349



Gambar 4. 14 Grafik Evaluasi Input Tes 5

Tabel 4. 6 dan Gambar 4. 14 diatas menyajikan data evaluasi dan menampilkan grafik evaluasi dari proses tes yang dilakukan pada data test kelima yang dijalankan pada beberapa model yang berbeda untuk melihat seberapa baik model-model tersebut dalam melakukan rekonstruksi citra sidik jari. Data tes kelima ini dirancang dengan level atau tingkat kerusakan paling parah dibandingkan dengan data tes lain.

Nilai *CLIP-IQA* secara keseluruhan meningkat namun pada model 120 dan model 200 yang mengalami penurunan. Secara otomatis dua model tersebut akan di keluarkan dari kandidat model dengan performa terbaik. Untuk nilai *CLIP-IQA* pada model 160 menunjukkan nilai yang tertinggi diantara model yang lain dengan artian memiliki kualitas kejernihan tertinggi dibanding inputnya yang merupakan tanda baik. Sama halnya seperti kasus sebelumnya, disini agar lebih memudahkan evaluasi, akan diambil data dari *LPIPS* dan *Edge Preservation Score* untuk melihat dari model 100 dan juga model 160. Model 40 secara otomatis tidak dipertimbangkan karena memiliki nilai *LPIPS* terendah yang mengindikasikan sangat mirip dengan input secara subjektif manusia namun juga memiliki nilai *Edge Preservation Score* yang mana mengartikan sangat sedikit kontur penting atau detail struktur yang terdapat pada sidik jari yang berpeluang tinggi dapat mengubah identitas pemilik sidik jari. Untuk model 100 dan model 160 akan dipilih dari nilai *LPIPS* dan nilai *Edge Preservation Score* tertinggi yang mana hal tersebut menunjukkan bahwa dari gambar yang memiliki kerusakan ekstrim jika dilihat dari subjektif manusia saat setelah dilakukan rekonstruksi pasti harus berubah signifikan namun juga harus tetap mempertahankan kontur penting atau detail struktur yang terdapat pada sidik jari agar tidak mengubah identitas. Sehingga dapat ditarik kesimpulan yang memiliki performa terbaik dengan pertimbangan tersebut ialah model 160 dimana memiliki nilai *LPIPS* diangka 0,24 dan memiliki nilai *Edge Preservation Score* diangka 0,84 yang artinya ada sekitar 84% kontur dipertahankan dari kerusakannya.


Sebelum melakukan penarikan kesimpulan maka akan kita bandingkan semua grafik dari data yang ada meliputi *Gen Loss*, *Disc loss*, *PSNR* dan *SSIM* dari data *training*, *PSNR* dan *SSIM* dari data validasi, juga *Clip IQA*, *LPIPS* dan *EPS* dari

data *testing*. Evaluasi lanjutan ini lebih berfungsi atau ditujukan untuk melihat adanya tanda-tanda terjadinya *overfitting*. Data selengkapnya pada tabel berikut :

Tabel 4. 7 Data *training*


Epoch	Generator Loss	Discriminator Loss	PSNR	SSIM
40	3,597	0,8602	29,13	0,9711
100	4,7618	0,6963	28,38	0,9652
120	4,7233	0,699	28,56	0,9662
160	5,7488	0,4936	28,97	0,9673
200	8,3794	0,2149	27,80	0,9565

Pada tabel 4.7 diatas adalah data dari *epoch* 40, 100, 120, 160 dan 200 yang memuat nilai dari *generator loss*, *discriminator loss*, *PSNR* dan *SSIM*, dari data ini akan dibuat grafiknya masing-masing.



Gambar 4. 15 Grafik Training Gen Loos, Disk Loss, PSNR dan SSIM

Gambar 4.15 memuat 4 buah grafik saat *training* yang meliputi *Gen Loss*, *Disk Loss*, *PSNR* dan *SSIM*. Hasil *overlay* dari keempat grafik tersebut dapat dilihat pada gambar 4.16 dibawah ini :



Gambar 4. 16 Grafik *Training overlay Gen Loos, Disk Loss, PSNR dan SSIM*

Berdasarkan Gambar 4.16 diatas, pada tahap awal pelatihan (sekitar model 40 hingga 100), generator dan *discriminator* masih berada dalam fase pembelajaran, dimana *generator loss*nya naik dan diimbangi *discriminator loss*nya yang semakin menurun. Keduanya berusaha belajar menyesuaikan diri sehingga kualitas citra hasil rekonstruksi belum stabil. Pada tahap model 100 hingga 160, *generator loss* dan *discriminator loss* menunjukkan pola keseimbangan, *PSNR* dan *SSIM* terlihat relatif stabil dan nilainya cukup tinggi. Dari kondisi ini dapat dilihat bahwa model dapat dikatakan mencapai performa yang cukup optimal. Namun, ketika pelatihan dilanjutkan ke model 200, tanda-tanda *overfitting* mulai terlihat. Walaupun *generator loss* terus meningkat dan *discriminator loss* semakin rendah, namun *PSNR* dan *SSIM* justru terlihat menurun. Pola ini menunjukkan bahwa meskipun *epoch* ditambah, kualitas citra tidak lagi meningkat dan justru cenderung menurun, sehingga dapat dikatakan bahwa titik 160 merupakan kondisi optimal dari proses pelatihan.


Setelah kita lihat grafik data hasil *training* dan mulai terlihat titik optimalnya di model 160, maka langkah berikutnya adalah mengecek apakah pola tersebut muncul juga pada grafik data validasi. Apabila tren yang ada di *training* juga terjadi

pada validasi, maka kita bisa melihat sejauh mana model benar-benar bekerja dengan baik di luar data yang dilatihnya.

Tabel 4. 8 Data *training*, validasi dan *test*


Epoch	PSNR Training	PSNR Val	PSNR Test	Gap Train-Val	Gap Train-Test
40	29,13	19,59	20,43	9,54	8,70
100	28,38	20,39	20,33	7,99	8,05
120	28,56	20,81	20,39	7,75	8,17
160	28,97	21,18	20,31	7,79	8,66
200	27,8	21,19	20,25	6,61	7,55

Tabel diatas memuat data dari *PSNR training*, *PSNR validasi*, *PSNR test* maupun gap/ perbedaan nilai dari *PSNR training* terhadap *PSNR validasi* dan *PSNR training* terhadap *PSNR test*. Dari tabel tersebut dapat dibuat grafik sebagai berikut



Gambar 4. 17 Grafik *PSNR (training, validasi dan test)*

Grafik diatas memuat nilai-nilai dari *PSNR training*, *PSNR validasi* dan *PSNR test* pada *epoch* 40, 100, 120, 160 dan 200. Agar kita mengetahui ada tidaknya *overfitting* maka kita harus melihatnya dari gap atau perbedaan/selisih nilai dari *PSNR training* terhadap *PSNR validasi* juga *PSNR training* terhadap *PSNR test*. Grafik gap dari nilai-nilai tersebut dapat dilihat pada grafik berikut :



Gambar 4. 18 Grafik Gap *PSNR* (*training* dengan validasi dan *test*)

Dari grafik tersebut dapat dilihat bahwa Nilai *PSNR Training* menurun dari 29,13 (*epoch* 40) menjadi 27,8 (*epoch* 200). Sementara itu, *PSNR Validasi* meningkat dari 19,59 ke 21,19 dalam rentang *epoch* yang sama. Pola ini menghasilkan pengecilan gap *PSNR training* dengan *PSNR Validasi* dari 9,54 menjadi sekitar 6,61. Pengecilan gap ini menunjukkan bahwa meskipun performa pada data training sedikit menurun, kemampuan model untuk menggeneralisasi terhadap data validasi justru semakin membaik. Hal ini menandakan adanya pencegahan *overfitting* dan adanya generalisasi yang semakin meningkat (Ghojogh dkk. 2023).


Pada *PSNR Test*, gap dengan *PSNR validasi* mempunyai nilai relatif stabil di kisaran 20,2–20,4. Gap ini dapat dikatakan cukup kecil, misalnya di epoch 160–200, selisihnya hanya sekitar 0,1–0,9, hal ini menandakan adanya konsistensi generalisasi. Dengan kata lain, dari sisi *PSNR*, model tidak menunjukkan *overfitting* yang signifikan. Keselarasan performa antara *PSNR validasi* dan *PSNR test* yang mempunyai gap yang kecil dan nilai yang stabil merupakan indikator penting bahwa model memiliki kemampuan generalisasi yang baik dan bukan sekadar menghafal data training (Heckel dkk. 2021).

Selain *PSNR*, hasil *training* juga bisa dilihat dari sisi *SSIM* agar kita bisa melihat sejauh mana model dapat memberikan gambaran seberapa mirip struktur citra hasil dengan aslinya.

Tabel 4. 9 Data *training*, validasi dan *test*

Epoch	SSIM Training	SSIM val	SSIM Test	Gap Train-Val	Gap Train-Test
40	0,9711	0,9149	0,9014	0,0562	0,0697
100	0,9652	0,9352	0,8934	0,0300	0,0718
120	0,9662	0,9391	0,8919	0,0271	0,0743
160	0,9673	0,9433	0,8959	0,0240	0,0714
200	0,9565	0,8698	0,8267	0,0867	0,1298


Tabel diatas memuat data dari *SSIM training*, *SSIM validasi*, *SSIM test* maupun gap/ perbedaan nilai dari *SSIM training* terhadap *SSIM validasi* dan *SSIM training* terhadap *SSIM test*. Dari tabel tersebut dapat dibuat grafik sebagai berikut :



Gambar 4. 19 Grafik Gap *SSIM (training, validasi dan test)*

Grafik diatas memuat nilai-nilai dari *SSIM training*, *SSIM validasi* dan *SSIM test* pada *epoch* 40, 100, 120, 160 dan 200. Dapat dilihat bahwa hasil *SSIM training* selalu tinggi antara 0,9565 sampai 0,9711, sedangkan pada *SSIM Validasi* terlihat

nilai yang cukup variatif. Agar kita mengetahui ada tidaknya *overfitting* maka kita harus melihatnya dari gap atau perbedaan/selisih nilai dari *SSIM training* terhadap *SSIM validasi* maupun *SSIM training* terhadap *SSIM test*. Grafik gap dari nilai-nilai tersebut dapat dilihat pada grafik berikut :



Gambar 4. 20 Grafik Gap *SSIM* (*training* dengan validasi dan test)

Pada grafik gap antara *SSIM training* dengan *SSIM validasi* di *epoch* 40 ada gap yang cukup besar yaitu 0,0562, tetapi semakin menurun sampai *epoch* 160 dengan gap sebesar 0,024 (gap terkecil). Namun, di *epoch* 200, gap kembali naik tajam dan melebihi gap di *epoch* 40, dan gap di *epoch* 200 menjadi 0,0867. Hal ini merupakan tanda yang jelas merupakan indikasi terjadinya *overfitting*. Model terus menghafal data *training*, tetapi performanya terhadap data validasi menurun drastis. Overfitting dapat dikenali dari adanya gap besar antara performa model pada data *training* dan validasi. Penurunan nilai gap mencerminkan model yang mulai menggeneralisasi dengan lebih baik, sedangkan peningkatan/pelebaran gap kembali menjadi sinyal kuat bahwa model telah kehilangan kemampuan generalisasi (Ghojogh dkk. 2023).

Berbeda dengan *SSIM validasi*, nilai gap terkecil antara *SSIM training* dengan *SSIM test* ada di *epoch* 40 dengan nilai 0,06968. Di *epoch* 160 ini, nilai gapnya 0,07138 dan bisa dikatakan perbedaannya tidak terlalu banyak. Di *epoch* 200, nilai gap naik tajam menjadi 0,12976. Di *epoch* 160 ke *epoch* 200, kenaikan ini selaras

dengan yang terjadi di gap validasi dan hanya beda di awal yaitu di *epoch* 40. Perbedaan performa yang lebih rendah pada saat test adalah sesuatu yang wajar dan justru menunjukkan bahwa model belum sepenuhnya *overfitting*, dan model masih menjaga kapabilitas generalisasi meskipun performa pada *test* tampak sedikit menurun (Azar dkk. 2024).

Berdasarkan evaluasi *PSNR* maupun *SSIM*, pada evaluasi *PSNR* menunjukkan tren yang lebih stabil dengan gap kecil antara validasi dan *test*, sehingga metrik ini mengindikasikan model relatif konsisten. Sedangkan pada *SSIM* gap yang mengecil hingga *epoch* 160, lalu naik di *epoch* 200, memperlihatkan tanda *overfitting*. Oleh karena itu, meskipun *PSNR* Validasi terus meningkat hingga *epoch* 200, kombinasi analisis gap *PSNR* dan *SSIM* menunjukkan bahwa *epoch* 160 adalah titik optimal, karena saat itu *SSIM* Validasi mencapai nilai tertinggi dengan gap *training* dengan validasi yang paling kecil. Hasil pada *test* hanya digunakan sebagai konfirmasi akhir kemampuan untuk generalisasi. Pemilihan model terbaik dipilih berdasarkan pemantauan pada data validasi dan bukan pada data *training* maupun data *test* (Heckel dkk. 2021)

Setelah pola dari hasil *training*, validasi maupun test mulai terlihat, tahap selanjutnya adalah masuk ke bagian evaluasi. Pada tahap ini, perbandingan antara *generator loss*, *discriminator loss*, dan metrik evaluasi berbasis kualitas citra seperti *CLIP-IQA* jadi penting untuk dilihat. Diharapkan tanda-tanda *overfitting* lebih mudah terlihat, dimana model terus belajar tapi hasilnya justru tidak semakin bagus. Jadi, dengan membandingkan keduanya kita bisa tahu apakah pola yang muncul benar-benar sejalan dengan hasil testing dan validasi atau malah menunjukkan hasil yang berbeda.

Tabel 4. 10 Data *testing*

Model	CLIP-IQA (Input)	CLIP-IQA (Output)	LPIPS	Edge Preservation Score
40	0,55772	0,5756	0,11672	0,71336
100	0,55772	0,57466	0,13618	0,90574
120	0,55772	0,53098	0,13446	0,89378


160	0,55772	0,59412	0,13108	0,91378
200	0,55772	0,41278	0,16310	0,82274

Tabel 4.9 memuat data dari *Clip-IQA input*, *Clip-IQA output*, *LPIPS* dan *EPS*. Untuk evaluasi lanjutan kita akan membandingkan grafik dari *generator loss*, *discriminator loss* (dari data *training*) dengan *Clip-IQA*. Masing-masing dibuat grafik sebagai berikut :



Gambar 4. 21 Grafik *Gen loss*, *Disk loss* dan *Clip IQA*

Dari semua grafik diatas selanjutnya dioverlay menjadi sebuah grafik sebagai berikut :




Gambar 4. 22 Overlay Grafik *Gen loss*, *Disk loss* dan *Clip IQA*

Kalau kita amati lebih detail, bagian yang paling menarik justru ada di *Clip-IQA output*. Pada model 40 sampai 100, pergerakannya masih cukup stabil, bisa


dibilang tidak ada lonjakan besar. Artinya, kualitas citra hasil restorasi masih sejalan dengan input. Pada model 120 terlihat ada penurunan *Clip-IQA output*, hal ini dianggap sebagai proses model sedang belajar dan beradaptasi. Pada model 160, *Clip-IQA output* sempat naik dan nilai yang tinggi. Ini menandakan model benar-benar ketemu titik *balance* antara hasil yang realistis dan kemiripan dengan data aslinya. Tapi menuju ke model 200, grafik *Clip-IQA output* justru turun cukup drastis, hal ini mengakibatkan kualitas citra yang dihasilkan malah menurun dan tidak konsisten lagi. Turunnya *Clip-IQA* secara drastis ini bisa jadi sinyal awal kalau model sudah mulai *overfitting*. Jadi meskipun model dilatih lebih lama, hasil akhirnya akan kehilangan kualitas.

Evaluasi lanjutan dilakukan dengan membandingkan grafik *PSNR*, *SSIM*, *LPIPS*, dan *EPS*. *EPS* menjadi sangat penting karena langsung berhubungan dengan kejelasan pola garis sidik jari. Jadi, lewat perbandingan ini bisa dilihat apakah hasil restorasi tidak hanya bagus secara umum, tapi juga tetap menjaga detail yang utama untuk identifikasi.



Gambar 4. 23 Grafik *LPIPS*, *EPS*, *PSNR* dan *SSIM*


Dari semua grafik diatas selanjutnya dioverlay menjadi sebuah grafik sebagai berikut :



Gambar 4. 24 Grafik *overlay* LPIPS, EPS, PSNR dan SSIM

Pada evaluasi dengan metrik *PSNR*, *SSIM*, *LPIPS* dan *EPS*, pola menarik mulai kelihatan. Pada model 40, semua metrik masih terbilang rendah, hal ini wajar karena model masih di awal proses belajar. Memasuki model 100, grafik *EPS* naik cukup tinggi, diikuti oleh *PSNR* dan *SSIM* yang juga stabil. Ini menunjukkan kalau detail garis sidik jari semakin terlihat jelas dan kualitas citra secara umum juga meningkat.

Dari kelima evaluasi data tes yang diproses pada lima model diatas, dapat disimpulkan bahwa model 160 merupakan model dengan performa dengan kualitas terbaik dalam menangani atau melakukan rekonstruksi pada citra sidik jari yang rusak. Dalam proses untuk mendapatkan data evaluasi diatas, citra yang rusak diproses pada model dengan ditampilkan dari *gradio* untuk memudahkan peneliti dalam mengambil datanya seperti yang terlihat pada Gambar 4. 25 yang memperlihatkan tampilan *User Interface* dari model rekonstruksi citra sidik jari ini yang didalamnya memuat evaluasinya juga. Adapun Gambar 4. 26 yang menampilkan tes jika citra sidik jari rusak dimasukkan pada modelnya dan terlihat tampilan dimana hasil rekonstruksi dari citra sidik jari rusak sudah diregenerasi dan diperbaiki serta tampil juga bagian evaluasi yang memuat nilai metrik evaluasi didalamnya.



Gambar 4. 25 User Interface Rekonstruksi & Evaluasi



Gambar 4. 26 Tampilan Proses Rekonstruksi

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini melakukan rekonstruksi citra sidik jari menggunakan *Deep Learning Pix2Pix GAN* yang dilakukan sebagai upaya penguatan sistem keamanan biometrik serta forensik digital. Pada implementasi ini, arsitektur *Pix2Pix GAN* yang digunakan ialah *Generator* yang berupa (U-Net) serta *Discriminator* yang berupa *PatchGAN* karena telah terbukti relevan dan efisien untuk menangani permasalahan seperti *image-to-image translation* seperti halnya rekonstruksi citra sidik jari ini.

Penelitian ini menggunakan metode evaluasi menggunakan beberapa metrik evaluasi diantaranya ialah *PSNR*, *SSIM*, *gen loss*, dan *disc loss* yang digunakan untuk melakukan analisa *training* model. Metrik evaluasi lain seperti halnya CLIP-IQA, LPIPS, *Edge Preservation Score (EPS)*, dan *Edge Strength (input & output)* untuk melakukan evaluasi pada proses testing model untuk melihat kinerja dari implementasi menggunakan model *Pix2Pix GAN* dan didapatkan hasil yang memuaskan dimana model dapat melakukan rekonstruksi citra sidik jari yang rusak dengan mempertahankan kontur penting atau detail struktur pada citra sidik jari.

5.2 Saran

Penelitian ini menghasilkan model *Deep Learning PIX2Pix GAN* untuk melakukan restorasi pada citra sidik jari yang rusak. Dalam prosesnya, terdapat beberapa hal yang dapat dikembangkan untuk penelitian selanjutnya diantaranya:

1. Memperbanyak dan menambah variasi dataset yang digunakan saat melakukan pelatihan model guna mendapatkan kualitas citra yang lebih detail.
2. Kontrol kekuatan dari *Generator* dan *Discriminator* agar selalu seimbang jika dilakukan dengan pelatihan lebih dari 200 epoch.
3. Kolaborasi dengan metode pengolahan citra lain untuk meningkatkan kualitas citra serta kinerja model.
4. Tambahkan metrik evaluasi lain untuk menilai kinerja model secara kompleks.

DAFTAR PUSTAKA

- Afsar, F. A., M. Arif, dan M. Hussain. 2004. "Fingerprint identification and verification system using minutiae matching." *National Conference on Emerging Technologies* 141–46.
- Al-Shahad, Huda F., Razali Yaakob, Nurfadhlin Mohd Sharef, Hazlina Hamdan, dan Hasyima Abu Hassan. 2025. "An Improved Pix2pix Generative Adversarial Network Model to Enhance Thyroid Nodule Segmentation." *Journal of Advances in Information Technology* 16(1):37–48.
- Arifin, Mohamad. 2022. "Sistem Pengamanan Mesin Atm Dengan Menggunakan Pengenalan Sidik Jari Dan Wajah Face Recognition Untuk Meminimalisir Cyberbanking Crime." *OISAA Journal of Indonesia Emas* 5(1):35–42.
- Atul S. Chaudhari, Atul S. Chaudhari. 2013. "A Study and Review on Fingerprint Image Enhancement and Minutiae Extraction." *IOSR Journal of Computer Engineering* 9(6):53–56.
- Azar, Saeideh Ghanbari, Lorenzo Tronchin, Attila Simko, Tufve Nyholm, dan Tommy Löfstedt. 2024. "From Promise to Practice: A Study of Common Pitfalls Behind the Generalization Gap in Machine Learning." *Transactions on Machine Learning Research* 2024.
- Barreiro-Garrido, Alvaro, Victoria Ruiz-Parrado, A. Belen Moreno, dan Jose F. Velez. 2024. "A Pix2Pix Architecture for Complete Offline Handwritten Text Normalization." *Sensors* 24(12).
- Chen, Luming, Fan Jiang, Hefang Zhang, Shibin Wu, Shaode Yu, dan Yaoqin Xie. 2016. "Edge preservation ratio for image sharpness assessment." *Proceedings of the World Congress on Intelligent Control and Automation (WCICA) 2016-Sept*(June):1377–81.
- Cohen, Gilad dan Raja Giryes. 2023. "Generative Adversarial Networks." *Machine Learning for Data Science Handbook: Data Mining and Knowledge Discovery*

Handbook, Third Edition 375–400.

Dewi, Wulan Wiryantari dan Ibrahim R. 2020. “Kekuatan Hukum Pelekatan Sidik Jari Penghadap Oleh Notaris Pada Minuta Akta.” *Acta Comitas* 5(3):436.

Fatmawati, Novenny. 2020a. “Kekuatan hukum sidik jari dalam pembuktian untuk menentukan tersangka tindak pidana pencurian.” 23.

Fatmawati, Novenny. 2020b. “Kekuatan hukum sidik jari dalam pembuktian untuk menentukan tersangka tindak pidana pencurian.” 23.

Gazali, Wikaria, Alexander Agung, dan Santoso Gunawan. 2012. “Analisis Dan Pembuatan Sistem Pengenalan Sidik Jari Berbasis Komputer Di Polda Metro Jaya.” *Analisis Dan Pembuatan Sistem Pengenalan Sidik Jari Berbasis Komputer Di Polda Metro Jaya* 12(9):55–65.

Ghazanfari, Sara, Siddharth Garg, Prashanth Krishnamurthy, Farshad Khorrami, dan Alexandre Araujo. 2023. “R-LIPS: An Adversarially Robust Perceptual Similarity Metric.”

Ghojogh, Benyamin dan Mark Crowley. 2023. “The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial.” (3).

Heckel, Reinhard dan Fatih Furkan Yilmaz. 2021. “Early Stopping in Deep Networks: Double Descent and How To Eliminate It.” *ICLR 2021 - 9th International Conference on Learning Representations*.

Jain, Anil K., Abhishek Nagar, dan Karthik Nandakumar. 2013. “Fingerprint template protection: From theory to practice.” *Security and Privacy in Biometrics* 187–214.

Kashkarov, Egor, Egor Chistov, Ivan Molodetskikh, dan Dmitriy Vatolin. 2024. “Can No-Reference Quality-Assessment Methods Serve as Perceptual Losses for Super-Resolution?”

Li, Hong An, Min Zhang, Zhenhua Yu, Zhanli Li, dan Na Li. 2022. “An improved pix2pix model based on Gabor filter for robust color image rendering.”

Mathematical Biosciences and Engineering 19(1):86–101.

Makrushin, Andrey, Venkata Srinath Mannam, dan Jana Dittmann. 2023. “Data-Driven Fingerprint Reconstruction from Minutiae Based on Real and Synthetic Training Data.” *Proceedings of the International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications* 4(Visigrapp):229–37.

Miyata, Takamichi. 2023. “Interpretable Image Quality Assessment via CLIP with Multiple Antonym-Prompt Pairs.” *IEEE International Conference on Consumer Electronics - Berlin, ICCE-Berlin* 39–40.

Narayanan, Athi. 2022. “Fingerprint Minutiae Extraction.” 2(11).

Nazeri, Kamyar, Eric Ng, dan Mehran Ebrahimi. 2018. “Image colorization using generative adversarial networks.” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10945 LNCS:85–94.

Pathak, Deepak, Philipp Krahenbuhl, Jeff Donahue, Trevor Darrell, dan Alexei A. Efros. 2016. “Context Encoders: Feature Learning by Inpainting.” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* 2016-Decem:2536–44.

Peng, Jialiang dan Yi Wu. n.d. “PPGAN: Privacy-preserving Generative Adversarial Network.”

Ritonga, Yudhy Azhari, Andi Najemi, dan Herry Liyus. 2024. “PAMPAS : Journal Of Criminal Law Volume 5 Nomor 3 , Tahun 2024 Fungsi Sidik Jari Pada Proses Penyidikan Dalam Mengungkap Tindak Pidana Pembunuhan Berencana.” 5:253–65.

Rowa, Arianti Magi dan Nikmatul Iza. 2021. “Profil Fingerprinting (Sidik Jari) pada Populasi Suku Ububewi Di Wanukaka Sumba Barat, Nusa Tenggara Timur, Indonesia.” *Prosiding Seminar Nasional IKIP Budi Utomo* 2(01):289–95.

- Sadykova, Diana dan Alex Pappachen James. 2017. "Quality assessment metrics for edge detection and edge-aware filtering: A tutorial review." *2017 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2017* 2017-Janua(2):2366–69.
- Santosa, Pratama Yoga, Ema Rachmawati, Tjokorda Agung, dan Budi Wirayuda. 2021. "Translasi Citra Malam Menjadi Siang Menggunakan Deep Convolutional Generative Adversarial Network." *eProceedings of Engineering* 8(1).
- Shehu, Yahaya Isah, Ariel Ruiz-Garcia, Vasile Palade, dan Anne James. 2018. "Sokoto Coventry Fingerprint Dataset." 103:5–7.
- Tahmid, Marjana, Md Samiul Alam, Namratha Rao, dan Kazi Muhammad Asif Ashrafi. 2023. "Image-to-Image Translation with Conditional Adversarial Networks." *Proceedings of 2023 IEEE 9th International Women in Engineering (WIE) Conference on Electrical and Computer Engineering, WIECON-ECE 2023* 468–72.
- Vikram Mutneja, Dharampal. 2015. "Methods of Image Edge Detection: A Review." *Journal of Electrical & Electronic Systems* 04(02).
- Wang, Jianyi, Kelvin C. K. Chan, dan Chen Change Loy. 2023. "Exploring CLIP for Assessing the Look and Feel of Images." *Proceedings of the 37th AAAI Conference on Artificial Intelligence, AAAI 2023* 37:2555–63.
- Wang, Ting Chun, Ming Yu Liu, Jun Yan Zhu, Andrew Tao, Jan Kautz, dan Bryan Catanzaro. 2018. "High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs." *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* 8798–8807.
- Weng, Weihao dan Xin Zhu. 2021. "INet: Convolutional Networks for Biomedical Image Segmentation." *IEEE Access* 9:16591–603.
- Widiatmika, Keyza Pratama. 2015. "No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title." *Etika Jurnalisme*

Pada Koran Kuning : Sebuah Studi Mengenai Koran Lampu Hijau 16(2):39–55.

Winda, Tri Wulandari, Ruslan Renggong, dan Abdul Salam Siku. 2019. “FUNGSI SIDIK JARI DALAM PENGUNGKAPAN KASUS TINDAK PIDANA PEMBUNUHAN (Studi Kasus pada Ditreskrimum Polda Sulawesi Selatan).” *Indonesian Journal of Legality of Law* 2(1):1–5.

Wolf, Stephen dan Margaret Pinson. 2009. “Reference Algorithm for Computing Peak Signal to Noise Ratio (PSNR) of a Video Sequence with a Constant Delay.” 1–18.

Xu, Bing, Naiyan Wang, Tianqi Chen, dan Mu Li. 2015. “Empirical Evaluation of Rectified Activations in Convolutional Network.”

Xu, Maojie. 2024. “Denoising astronomical images using an enhanced Pix2Pix model.” *Applied and Computational Engineering* 88(1):259–66.

Yang, Jiang dan Richard Xian Ke Gao. 2022. “A Novel Circuit Modeling Approach for Electromagnetic ‘Black-box’ Problems based on Generative Adversarial Networks and Partial Element Equivalent Circuit Method.” *2022 Asia-Pacific International Symposium on Electromagnetic Compatibility, APEMC 2022* (September 2022):72–74.

Zaeri, Naser. 2011. “Minutiae-based Fingerprint Extraction and Recognition.” *Biometrics* (December).