

Pembangkitan Citra Wajah dari Sketch Wajah Menggunakan CycleGAN

Muhammad Azki Rasyid, Reza Fuad Rachmadi, Diah Puspito Wulandari
Departemen Teknik Komputer, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: fuad@its.ac.id

Abstrak—Penggunaan sketsa wajah merupakan alat bantu yang digunakan lembaga penegak hukum dalam melakukan proses identifikasi tersangka tindak kriminal. Sketsa wajah digunakan ketika tidak terdapat foto dari tersangka tindak kriminal di tempat kejadian perkara. Sketsa wajah digunakan dalam proses identifikasi mugshot pada database dengan menggunakan sistem face recognition, dikarenakan sketsa wajah memiliki modalitas yang berbeda dengan citra wajah seperti halnya tekstur wajah, maka dibangkitkanlah citra wajah baru dari input sketsa wajah yang dimiliki sehingga dapat memiliki tekstur yang dapat menyerupai citra wajah. CycleGAN merupakan metode yang digunakan dalam melakukan tugas imaged-to-image translation, metode tersebut dapat digunakan dalam melakukan style transfer. Oleh karena itu, dalam penelitian tugas akhir ini dikembangkan sebuah model yang berfungsi untuk membangkitkan citra wajah dari sketsa wajah sehingga dapat mengolah sketsa wajah menjadi citra wajah yang memiliki tekstur wajah.

Kata Kunci—Computer Vision, Deep-Learning, GAN, Image Synthesis.

I. PENDAHULUAN

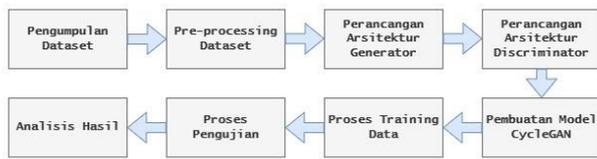
SKETSA wajah merupakan salah satu alat bantu yang digunakan oleh pihak otoritas lembaga penegak hukum dalam melakukan proses identifikasi dan penangkapan tersangka yang terlibat dalam tindak pidana selain metode sidik jari, *dactyloscopy*, metode balistik, dan metode deteksi kebohongan. Sketsa wajah digunakan ketika tidak dididapkannya foto wajah dari tersangka di tempat kejadian perkara. Sketsa wajah tersebut merupakan gambaran dari tersangka tindak kriminal yang belum diketahui identitasnya, namun fitur wajahnya diketahui oleh saksi mata. Walaupun sketsa wajah memiliki perbedaan dengan foto wajah baik dalam segi gaya dan penampilannya, sketsa wajah dapat menjadi sebuah media untuk mengenali seorang individu [1]. Penggambaran sketsa wajah tersebut digambarkan entah oleh seniman sketsa forensik yang berpengalaman maupun dengan menggunakan perangkat lunak komputer dalam menghasilkan *composite sketch*. Sketsa wajah tersebut digambarkan berdasarkan deskripsi lisan yang diberikan oleh saksi mata di tempat kejadian perkara. Kemudian setelah sketsa wajah dari tersangka telah dibuat, pihak otoritas lembaga penegak hukum menyebarkan sketsa wajah tersebut dengan harapan seseorang dapat mengenali wajah yang digambarkan dan memberikan informasi terkait yang dapat digunakan sebagai batu loncatan ke proses penangkapan [2].

Perkembangan ilmu *computer vision* dalam beberapa tahun terakhir telah membantu manusia dalam menyelesaikan tugasnya, seperti contohnya dalam menggunakan pengenalan wajah sebagai sistem keamanan maupun pencarian. *Face Recognition* pada umumnya merupakan sebuah proses untuk mengidentifikasi maupun

memverifikasi identitas seseorang dengan menggunakan wajahnya. Penggunaan *face recognition* telah diterapkan oleh pihak otoritas hukum dalam mencari tersangka tindak pidana. Foto wajah yang didapatkan pihak otoritas hukum di tempat kejadian perkara dicocokkan secara manual dengan *database mugshot* yang dimiliki. Foto wajah tersebut dapat diperoleh baik melalui saksi mata, kamera CCTV, dan jenis foto atau rekaman lainnya. Pencocokan wajah tersebut dilakukan secara manual oleh pihak yang ditugaskan. Tugas tersebut yang sebelumnya dilakukan secara manual kemudian diotomasi dengan menggunakan *face recognition* dalam memeriksa wajah asli tersangka tindak pidana dalam *database mugshot* yang dimiliki [3]. Ketika terjadi sebuah kondisi dimana tidak dapat diperolehnya foto wajah dari tersangka tersebut, pembuatan sketsa wajah digunakan sebagai mitigasi. Seperti yang telah dibahas sebelumnya, sketsa wajah digunakan ketika citra wajah dari tersangka tindak kriminal tidak dapat diperoleh, keberadaan sketsa wajah tersebut diharapkan dapat digunakan sebagai *input* dalam sistem *face recognition* yang dimiliki pihak otoritas hukum, namun bagaimana jika sketsa wajah tersebut dapat diolah terlebih dahulu untuk dijadikan sebuah citra wajah sehingga dapat mempermudah sistem dalam mengidentifikasi tersangka tindak pidana tersebut.

Pada dasarnya telah terdapat teknologi atau model pengolahan citra untuk melakukan *image-to-image translation* yang digunakan dalam mentranslasi sebuah citra. CycleGAN merupakan salah satu metode *Generative Adversarial Networks* (GAN) yang dirancang untuk melakukan tugas *imaged-to-image translation* atau *style transfer*, dengan contoh pada proses pengubahan lukisan dengan gaya seniman Claude Monet menjadi sebuah foto hasil tangkapan kamera [4]. Dalam paper yang telah diterbitkan, CycleGAN memiliki keunggulan dalam melakukan *image-to-image translation*, lalu terdapat penerapan dalam pengimplementasian CycleGAN dengan menambahkan fitur *identity-aware* pada metode tersebut untuk menerjemahkan citra wajah menjadi sketsa wajah. Walaupun sketsa wajah dan citra wajah pada dasarnya merupakan sebuah wajah, sketsa wajah dan citra wajah memiliki perbedaan baik dalam segi tekstur maupun bentuk. Penggambaran sketsa wajah dengan menggunakan pensil di atas kertas memiliki tekstur yang berbeda jika dibandingkan dengan kulit yang dihasilkan oleh foto [1], oleh karena itu proses *face recognition* dengan menggunakan sketsa wajah sebagai *input* telah menjadi tantangan yang sulit, walaupun terdapat beberapa metode sudah diterapkan dalam memecahkan permasalahan tersebut, tetap terdapat banyak kesulitan dalam *face recognition* sketsa wajah ke citra wajah dikarenakan keduanya memiliki modalitas yang berbeda [5].

Berdasarkan informasi yang telah dipaparkan sebelumnya, maka diperlukan sebuah penelitian untuk



Gambar 1. Blok diagram metodologi.



Gambar 2. Pratinjau dataset CUHK face sketch database.

mengembangkan model *deep learning* yang dapat melakukan *image translation* khususnya pada pembangkitan citra wajah dari sketsa wajah menggunakan CycleGAN sehingga dapat menimbulkan tekstur citra wajah pada sketsa wajah yang dimiliki. Kedepannya, diharapkan penelitian ini dapat digunakan sebagai pijakan untuk diimplementasikan kedalam proses penyidikan tersangka tindak kriminal, dan digunakan dalam implementasi penggunaan *face recognition*.

II. PENELITIAN TERKAIT

Generative Adversarial Networks (GAN) merupakan metode *deep learning* yang dikembangkan pada tahun 2014 [6]. Dikembangkan oleh Ian J. Goodfellow et al. untuk melakukan prediksi, digunakan secara luas dalam tugas *image generation*, *video generation*, dan *voice generation*. Metode tersebut mengestimasi model *generative* dengan menggunakan proses *adversarial* dimana dilakukan proses training pada dua model secara bersamaan, terdiri dari model *generator* untuk menangkap data untuk diperkirakan probabilitasnya oleh model *discriminator* sampai didapatkan kesalahan *D* [6].

Pada paper *Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks*, Zhu et al. melakukan penelitian mengenai *image-to-image translation* dengan menggunakan *unpaired dataset* untuk menangkap karakteristik khusus dari suatu koleksi gambar dan mencari tahu bagaimana karakteristik tersebut dapat diterjemahkan ke dalam koleksi gambar lainnya. Dalam penelitian tersebut, Zhu et al. menerjemahkan *photograph* menjadi gaya lukisan, kuda menjadi zebra, dan *landscape summer* menjadi *winter* [4].

Pada paper *An Introduction to Image Synthesis with Generative Adversarial Nets*, Huang et al. melakukan penelitian mengenai perbandingan metode GAN yang digunakan dalam menerapkan *image synthesis* dan *image-to-image translation*. Dalam penelitian tersebut CycleGAN dan DualGAN diterapkan dalam melakukan penerjemahan gambar *black and white* menjadi *colored* [7].

Pada paper *Identity-Aware CycleGAN for Face*

Tabel 1.
Jumlah data pada dataset CUHK face sketch database.

Jumlah dataset CUHK face sketch database.	
Train set sketsa wajah	88
Train set citra wajah	88
Test set sketsa wajah	100
Test set citra wajah	100

PhotoSketch Synthesis and Recognition, Fang et al. melakukan penelitian *face photo-sketch synthesis* dengan menggunakan *Identity-Aware CycleGAN* (IACycleGAN). Dalam penelitian tersebut menerapkan metode untuk meningkatkan performa CycleGAN dalam melakukan *photo-sketch synthesis* dengan menambahkan pengawasan lebih dalam *facial regions*, seperti mata dan hidung yang dimana merupakan aspek penting dalam *identity recognition* [8].

Pada paper *Pengenalan Sketsa Wajah menggunakan Principal Component Analysis* sebagai Aplikasi Forensik, Purwandari et al. melakukan penelitian pencocokan sketsa menggunakan CUFS database dengan metode PCA. Penelitian tersebut menggunakan sketsa sebagai *input* sistem untuk dicocokkan dengan citra wajah [1].

Penelitian yang sudah dilakukan sebelumnya memiliki kesamaan tujuan utama dalam melakukan *image-to-image translation* pada sebuah citra, namun belum bertujuan untuk melakukan *image-to-image translation* pada sketsa wajah menjadi citra wajah. Terdapat penelitian menggunakan CycleGAN dengan menggunakan dataset yang sama, namun bertujuan untuk membangkitkan sketsa wajah dari citra wajah dan menggunakan metode CycleGAN yang berbeda yaitu IACycleGAN.

III. DESAIN DAN IMPLEMENTASI SISTEM

Penelitian tugas akhir ini memanfaatkan disiplin ilmu dalam bidang *computer vision* dan *deep learning* yang bertujuan untuk membangkitkan citra wajah dari sketsa menggunakan CycleGAN sebagai metode. CycleGAN merupakan sebuah implementasi metode GAN untuk melaksanakan tugas *image-to-image translation*. Pada penelitian ini akan menggunakan CycleGAN dengan menggunakan arsitektur *ResNet blocks* dan *U-Net blocks*.

Gambar 1 menggambarkan blok diagram metodologi alur penelitian yang dilakukan. Terdapat tahapan secara umum yang digambarkan untuk menjelaskan alur dari penelitian yang dilakukan, yaitu pengumpulan dataset, pengolahan dataset, perancangan arsitektur *generator*, perancangan arsitektur *discriminator*, pembuatan model CycleGAN, proses *training*, proses pengujian, dan analisis hasil.

Data yang digunakan pada penelitian ini menggunakan dataset CUHK face sketch database (CUFS) dan CUHK face sketch FERET database (CUFSF) [9-10]. Kedua dataset tersebut digunakan dalam melakukan riset *face sketch synthesis* dan *face sketch recognition*.

Pada dataset CUHK face sketch database terdapat 188 citra wajah dan 188 sketsa wajah dengan total 376 data. Dataset tersebut dikonfigurasi menjadi 100 *training image* pada citra wajah, 88 *testing image* pada sketsa wajah dan 88 *testing image* pada citra wajah. Gambar 2 merupakan pratinjau dari



Gambar 3. Pratinjau dataset CUHK face sketch FERET database.

Tabel 2.

Jumlah data pada dataset CUHK face sketch FERET database.

Jumlah dataset CUHK face sketch FERET database.	
Sketsa wajah	1194
Citra wajah	1194

dataset CUHK face sketch database. Tabel 1 menunjukkan pembagian *training* dan *testing* set pada dataset CUHK face sketch database.

Pada dataset CUHK face sketch FERET database terdapat 1194 citra wajah 1194 sketsa wajah dengan total 2388 data. Gambar 3 merupakan pratinjau dari dataset CUHK face sketch FERET database. Tabel 2 menunjukkan pembagian *training* dan *testing* set pada dataset CUHK face sketch FERET database.

A. Pembagian Data

Setelah data dikumpulkan, kedua dataset tersebut akan digunakan menjadi 3 variasi, variasi pertama menggunakan dataset CUHK face sketch database, variasi kedua menggunakan dataset CUHK face sketch FERET database, dan variasi ketiga menggabungkan kedua dataset tersebut. Kemudian dari dataset tersebut akan dibagi menjadi beberapa pembagian folder sebagai berikut:

1) Training

Train A dalam folder ini terdiri dari citra pada domain A berupa gambar sketsa yang akan dilatih menjadi domain B berupa citra wajah. Sedangkan *train B* dalam folder ini terdiri dari citra pada domain B berupa citra wajah yang akan dilatih menjadi domain A berupa gambar sketsa.

2) Testing

Test A: dalam folder ini terdiri dari citra pada domain A berupa gambar sketsa yang akan diuji menjadi domain B berupa citra wajah. Sedangkan *test B* dalam folder ini terdiri dari citra pada domain B berupa citra wajah yang akan dilatih menjadi domain A berupa gambar sketsa.

Pembagian data akan dibagi menjadi *training* dan *testing*, pembagian data dibagi berdasarkan persentase yang digunakan pada dataset CUHK face sketch database. Tabel 3, dan Tabel 4 menunjukkan jumlah pembagian pada *train test* dan *test set*.

B. Pre-processing Data

Setelah data dibagi akan dilakukan *pre-processing*, variasi dalam *pre-processing* akan dibagi menjadi dua, variasi pertama dengan *image* tanpa dilakukan *crop*, dan *image* yang dilakukan *crop*. *Image* akan dicrop menjadi

Tabel 3.

Pembagian dataset CUHK face sketch database.

Pembagian train set dan test set	
<i>Train A</i>	88
<i>Train B</i>	88
<i>Test A</i>	100
<i>Test B</i>	100

Tabel 4.

Pembagian dataset CUHK face sketch FERET database.

Pembagian train set dan test set	
<i>Train A</i>	561
<i>Train B</i>	561
<i>Test A</i>	633
<i>Test B</i>	633

close up wajah sehingga latar belakang diminimalisir dan bahu dihilangkan. Alasan dilakukan variasi ini untuk menguji *noise input* yang akan ditangani oleh model. Setelah itu *image* akan dilakukan *rescale* dan *resize* menjadi 256 piksel. Pada data *training* dan *testing*, *image* akan diberikan *scaling* sehingga memiliki *range* piksel sebesar $[-1, 1]$ dikarenakan tanh *activated generator* akan memiliki nilai sebesar $[-1, 1]$.

C. Perancangan Arsitektur Generator

Pada penelitian ini akan dibuat dua macam *generator* dengan menggunakan *modified ResNet blocks* dan *modified U-Net blocks* untuk dibandingkan. Karena CycleGAN menggunakan Instance Normalization, kedua *generator* tersebut akan menggunakan Instance Normalization, maka dari itu pada *modified U-Net blocks* juga akan digunakan Instance Normalization dari pada Batch Normalization.

1) Generator ResNet

Generator akan menggunakan model arsitektur *encoder-decoder*. Model akan melakukan *downsampling* atau *encoding* dari *input image* ke *bottleneck layer*, lalu diinterpretasikan kedalam *layer residual blocks* sebanyak sembilan *layer*, dilanjutkan dengan *layer upsample* untuk *decode* representasi *bottleneck* dari *image* menjadi ukuran *output image*. *Generator* memiliki *convolutional blocks* yang standar, tiap *convolutional layer* akan terdiri dari Instance Normalization, *activation* menggunakan relu dan *activation tanh* pada *convolutional block* terakhir.

2) Generator U-Net

Generator akan menggunakan model arsitektur *encoder-decoder* dengan menggunakan UNet. Model akan melakukan *downsampling* ke *bottleneck layer*, kemudian dilakukan *upsampling* untuk *decode* representasi *bottleneck*. Pada arsitektur U-Net ditambahkan *skip-connections* diantara *encoding* dan *decoding layer* yang menyerupai bentuk U. *Generator* memiliki *convolutional blocks* yang standar, tiap *convolutional layer* akan terdiri dari Instance Normalization, *activation* menggunakan relu dan *activation tanh* pada *convolutional block* terakhir.

D. Perancangan Arsitektur Discriminator

Pada penelitian ini *discriminator* akan menggunakan PatchGAN. PatchGAN merupakan tipe *discriminator* GAN

Tabel 5.
Konfigurasi *training*.

Konfigurasi <i>Training</i>	
Epoch	500
Learning Rate	0.0002
Buffer Size	256
Batch Size	1
Train Image Width	256
Train Image Height	256

untuk memprediksi $N \times N$ *patch image*. PatchGAN akan memprediksi setiap ukuran output menjadi 70×70 *patch* dari *input image*. Pada penelitian ini *discriminator* akan menggunakan implementasi desain arsitektur *convolutional layer* C64-C128-C256-C512.

E. Pembuatan Model CycleGAN

CycleGAN terdiri dari dua *generator* dan *discriminator*. Pada penelitian ini akan digunakan data untuk melakukan *image-to-image translation* dari sketsa wajah menjadi citra wajah. *Generator* 1 akan mengambil sketsa wajah sebagai *input* dan menghasilkan *output* citra wajah, kemudian *discriminator* 1 akan mengambil citra wajah dari hasil *output generator* 1 dan menghasilkan *ouput* berupa nilai kemiripan dari citra aslinya, berlaku hal yang sama dengan *generator* 2 dan *discriminator* 2 namun berkebalikan. Setiap GAN akan menggunakan *cycle consistency loss* untuk meyakinkan *generated image* merupakan terjemahan dari *input*. Pada penelitian ini akan digunakan dua model CycleGAN dengan menggunakan ResNet *blocks* dan U-Net *blocks*.

F. Proses Training

CycleGAN merupakan metode yang melibatkan *automatic training*, model akan menangkap karakteristik khusus dari suatu *domain image* tanpa harus dilakukan *pairing* pada *dataset* tersebut. CycleGAN merupakan sebuah *extension* dari arsitektur GAN yang melibatkan *learning* secara simultan dari dua model *generator* dan dua model *discriminator*.

1) Generator

Generator akan belajar untuk menghasilkan data palsu dengan umpan balik dari *discriminator*. *Generator* belajar untuk membohongi *discriminator* untuk mengklasifikasikan data palsu sebagai data nyata.

2) Discriminator

Discriminator merupakan *classifier* yang mencoba untuk membedakan data nyata dari data yang telah dibuat oleh *generator*. Pada penelitian ini *discriminator* akan menggunakan arsitektur PatchGAN 70×70 . *Discriminator* mempelajari data dari dua sumber, yaitu data nyata dan palsu. Data nyata didapatkan dari *training set* sebagai contoh positif selama proses *training*. Data palsu merupakan data yang dihasilkan oleh *generator*.

3) Konfigurasi Training

Proses *training* akan menggunakan konfigurasi dengan *epoch* sebesar 500, *learning rate* sebesar 0.0002. *Input* dari gambar. Konfigurasi *training* yang ditentukan pada penelitian ini akan diuraikan pada Tabel 5.

G. Proses Pengujian

Proses pengujian merupakan langkah terakhir dari suatu *network* atau konsep *machine learning*. Pada proses ini model yang telah melalui proses *training* dapat digunakan untuk memprediksi hasil. Pada penelitian ini model akan mencoba untuk memberikan *output* prediksi berupa citra wajah dengan *input* berupa sketsa wajah. Sketsa wajah tersebut diambil dari *test set* pada *dataset* yang digunakan. Setelah *test set* diujikan pada model, maka akan didapatkan sebuah *output* berupa citra *predicted* atau *generated images*. Citra tersebut akan diuji dengan menggunakan metode survei dan *face recognition*. Ketika citra wajah *generated* akan menghasilkan kualitas yang baik dan rekonstruksi dapat terlihat, model akan diuji dengan menggunakan MSE, PSNR, dan SSIM, kemudian digunakan metode *face recognition*.

Setelah data pada *test set* diuji, langkah selanjutnya akan digunakan sketsa wajah diluar *dataset* untuk menghasilkan citra wajah untuk menguji performa model.

Hasil model akan diuji dengan menggunakan DeepFace untuk mengidentifikasi citra *generated* pada sistem *face recognition*. DeepFace merupakan *framework face recognition* ringan dan sistem analisa atribut wajah (umur, jenis kelamin, emosi, ras) untuk python. Terdapat lima tahapan umum pada sistem tersebut berupa *detect*, *align*, *normalize*, *represent*, dan *verify* [11].

Pada penelitian ini, parameter yang digunakan *deepface* dalam membandingkan objek akan menggunakan perhitungan *distance* untuk mengidentifikasi kemiripan citra wajah, *deepface* akan mengidentifikasi wajah tersebut dengan menggunakan model berbasis MTCNN. Jika perhitungan *distance* tersebut mendekati citra wajah yang dibandingkan, maka DeepFace akan menganggap bahwa wajah tersebut memiliki identitas yang sama.

Ketika pengujian dengan menggunakan *test set* selesai dilakukan, selanjutnya akan digunakan sketsa wajah diluar *dataset* untuk mengukur hasil model. Data *input* akan berupa sketsa wajah yang didapatkan pada AR *face dataset*. Pada kondisi nyata, sketsa wajah tidak memiliki pasangan citra wajah seperti halnya pada *dataset* sehingga *ground truth* tidak dapat dihitung.

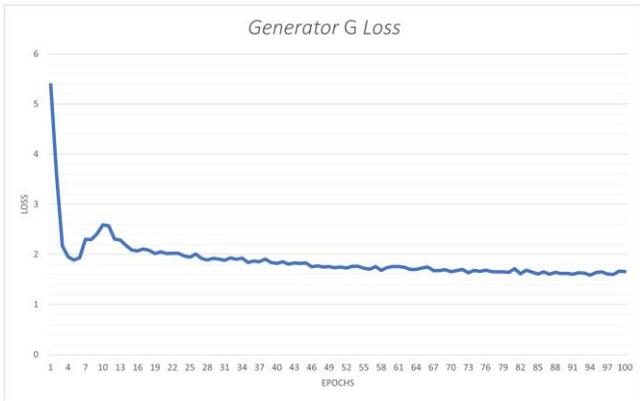
IV. PENGUJIAN DAN ANALISA

Pada bab ini dipaparkan hasil penelitian, pengujian, dan analisa dari desain sistem yang telah dirancang. Pengujian dilakukan dengan tujuan mengukur performa dan tingkat kesalahan dari sistem yang telah dirancang. Pengujian akan dilakukan dengan menggunakan implementasi *face recognition*, perhitungan MSE, PSNR, dan SSIM.

A. Hasil Training

Setelah tahap pembuatan arsitektur model selesai, maka akan dilanjutkan dengan proses *training*. Setelah proses *training* dilakukan, akan terdapat sebuah nilai yang merupakan gambaran seberapa besar suatu model yang dibangun dapat menjawab dari permasalahan yang ada. Hasil dari proses *training* yang didapatkan berupa *loss* dari kedua *generator* dan *discriminator*.

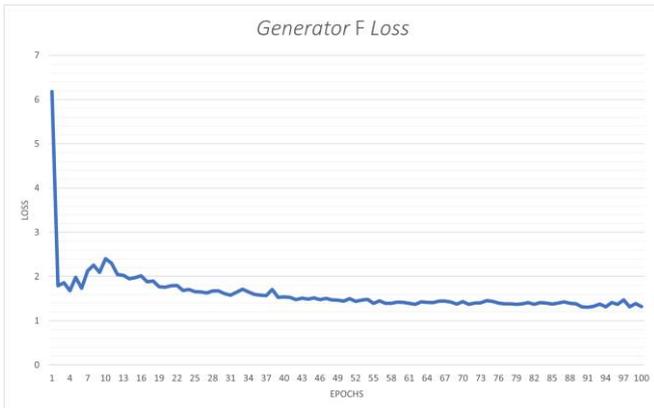
Dataset CUFS: Gambar 4 grafik *generator G loss dataset CUFS*, Gambar 5 grafik *generator F loss dataset CUFS*,



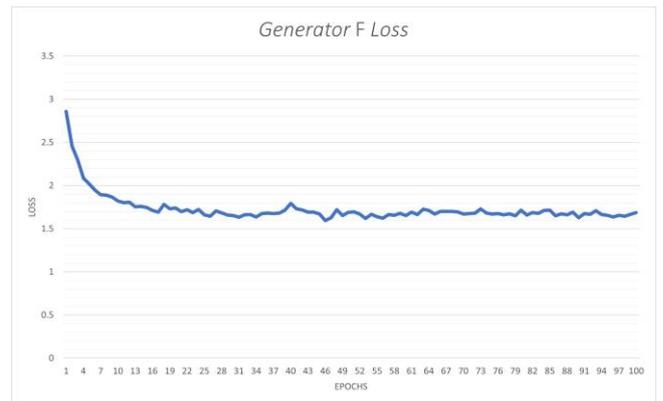
Gambar 4. Grafik generator G loss dataset CUFSS.



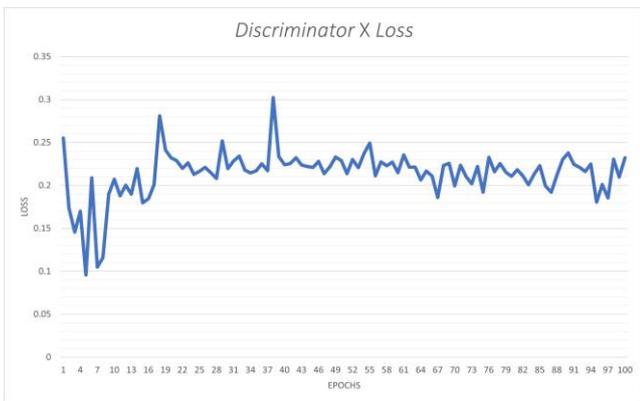
Gambar 8. Grafik generator G loss dataset CUFSS.



Gambar 5. Grafik generator F loss dataset CUFSS.



Gambar 9. Grafik generator F loss dataset CUFSS.



Gambar 6. Grafik discriminator X loss dataset CUFSS.



Gambar 10. Grafik discriminator X loss dataset CUFSS.



Gambar 7. Grafik discriminator Y loss dataset CUFSS.



Gambar 11. Grafik discriminator Y loss dataset CUFSS.

Gambar 6 grafik *discriminator X loss dataset CUFSS*, dan Gambar 7 grafik *discriminator Y loss dataset CUFSS*, merupakan hasil *training dataset CUFSS* menggunakan CycleGAN ResNet. Sedangkan *dataset CUFSS*: Gambar 8 grafik *generator G loss dataset CUFSS*, Gambar 9 grafik

generator F loss dataset CUFSS, Gambar 10 grafik *discriminator X loss dataset CUFSS*, dan Gambar 11 grafik *discriminator Y loss dataset CUFSS*, merupakan hasil *training dataset CUFSS* menggunakan CycleGAN ResNet.



Gambar 12. Hasil pengujian *test set* menggunakan CycleGAN ResNet *dataset* CUFS.



Gambar 13. Hasil pengujian *test set* menggunakan CycleGAN ResNet *dataset* CUFSF.

B. Hasil Testing

Setelah proses *training* dilakukan, selanjutnya akan dilakukan uji coba dengan menggunakan *test set*. Gambar pada *test set* akan berisi perbandingan antara *input* sketsa wajah dan *output* citra wajah *generated*.

Dataset CUFS: Gambar 12 merupakan hasil citra *generated* dari *dataset CUFS*. Sedangkan *dataset CUFSF*: Gambar 13 merupakan hasil citra *generated* dari *dataset CUFSF*.

C. Hasil Testing Dataset Cropped

Sebelumnya telah dipaparkan dan diuji hasil keberhasilan dari model dengan proses *training* tanpa melakukan *preprocessing cropped* pada *dataset*. Pada sebelumnya dilakukan pengujian berupa survei dan pengujian berupa implementasi *face recognition* dengan menggunakan model DeepFace berbasis MTCNN. Maka dari itu akan dicoba model dengan proses *training* dengan menambahkan fase *pre-processing cropped* pada *dataset*, gambar akan dicrop sampai hanya tinggal wajah.

Pada umumnya, GAN mengambil *random noise* sebagai *input* untuk dipelajari, maka dari itu jika *noise* pada latar belakang dan fitur pada sketsa dan foto seperti contohnya bahu dan kerah pakaian diminimalisir, maka variasi *noise* akan berkurang sehingga diprediksi model memungkinkan untuk mengkonstruksi citra menjadi lebih baik. Hasil berikut diharapkan dapat menjawab permasalahan dari hasil model yang sebelumnya telah dipaparkan.

1) Dataset CUFS

Pada bagian ini akan diuji model yang *training* dengan menggunakan *dataset CUFS*. Data *input* yang digunakan berupa 256x256 piksel dan data *output* berupa 256x256 piksel., *dataset* tersebut berwarna dan memiliki latar belakang berwarna biru.

Gambar 14 merupakan hasil citra *generated* dari *dataset CUFS*. Gambar 14 merupakan hasil pembangkitan citra wajah dari sketsa menggunakan CycleGAN berbasis ResNet *blocks*. Pada sebelah kiri gambar merupakan *input* sketsa



Gambar 14. Hasil pengujian *test set* menggunakan CycleGAN ResNet *dataset CUFS cropped*.

yang digunakan dan pada kanan merupakan hasil citra wajah *generated* yang dihasilkan.

2) Dataset CUFSF

Pada bagian ini akan diuji model yang *training* dengan menggunakan *dataset CUFSF*. Akan digunakan dua macam arsitektur, CycleGAN dengan menggunakan ResNet *blocks* dan U-Net *blocks*. Data *input* yang digunakan berupa 256x256 piksel dan data *output* berupa 256x256 piksel., *dataset* memiliki warna *grayscale* sehingga citra wajah dengan latar belakang berwarna hitam putih.

Gambar 15 merupakan hasil citra *generated* dari *dataset CUFSF*. Gambar 15 merupakan hasil pembangkitan citra wajah dari sketsa menggunakan CycleGAN berbasis ResNet *blocks*. Pada sebelah kiri gambar merupakan *input* sketsa yang digunakan dan pada kanan merupakan hasil citra wajah *generated* yang dihasilkan.

D. Analisis Hasil

Telah dipaparkan hasil dari beberapa model yang telah dibuat. Sebagian Model dapat membangkitkan citra wajah dengan baik dari sketsa wajah seperti pada Gambar 16, dan



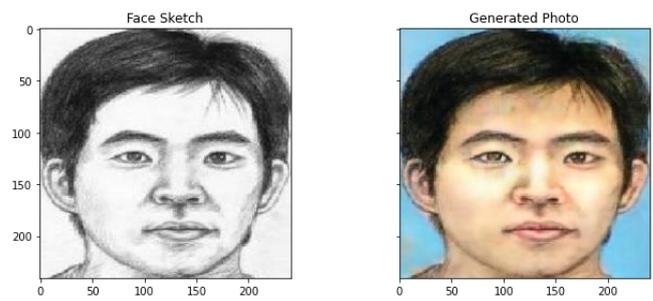
Gambar 15. Hasil pengujian *test set* menggunakan CycleGAN ResNet *dataset* CUFSS *cropped*.

sebagian model tidak dapat membangkitkan citra wajah dengan baik dari sketsa wajah seperti pada Gambar 17. CycleGAN mengambil *noise* sebagai input, pada Gambar 16 model dapat membangkitkan citra wajah dengan baik karena *noise* yang didapatkan lebih sedikit jika dibandingkan Gambar 17, hal tersebut dibuktikan dengan hasil jadi yang diperoleh, model dapat mempelajari bentuk sederhana, fitur yang dimiliki Gambar 16 lebih sedikit jika dibandingkan dengan Gambar 16, hal tersebut memiliki korelasi dengan *noise* yang dimiliki sehingga performa sangat berpengaruh.

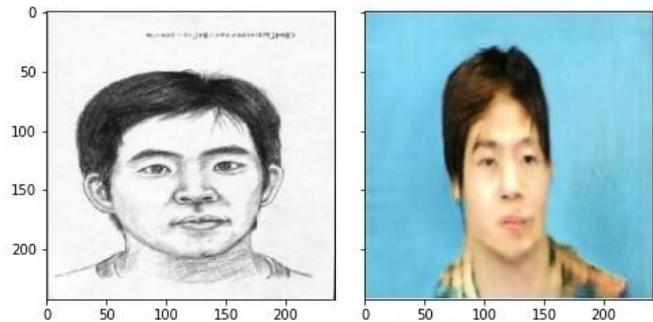
Kemudian akan dihitung MSE, PSNR, dan SSIM dari hasil gambar yang telah didapatkan.

Gambar 18 merupakan gambar perbandingan sketsa wajah (kiri) dan citra wajah *generated* (kanan), *Image Quality Metrics* dari citra wajah *generated* akan ditampilkan pada Tabel 6. Citra wajah *generated* memiliki nilai MSE yang tinggi, dikarenakan gambar tersebut memiliki perbedaan yang sangat jauh. PSNR yang dimiliki oleh citra wajah *generated* juga menunjukkan angka yang rendah, namun SSIM yang didapatkan memiliki nilai diatas 0.5.

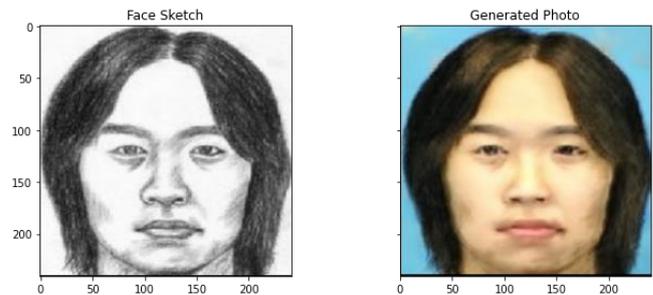
Gambar 19 merupakan gambar perbandingan citra wajah (kiri) dan citra wajah *generated* (kanan), *Image Quality Metrics* dari citra wajah *generated* akan ditampilkan pada Tabel 7. Citra wajah *generated* memiliki nilai MSE yang



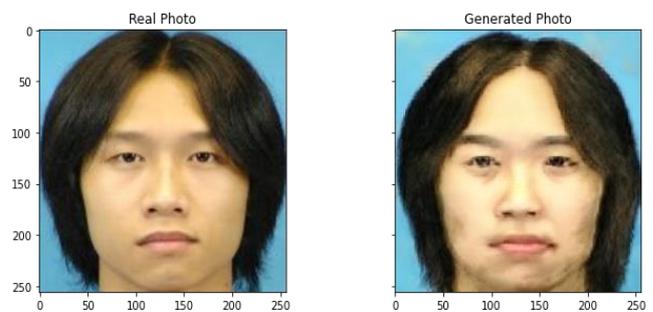
Gambar 16. Perbandingan pertama.



Gambar 17. Perbandingan kedua.



Gambar 18. Gambar perbandingan sketsa wajah dengan hasil citra *generated*.



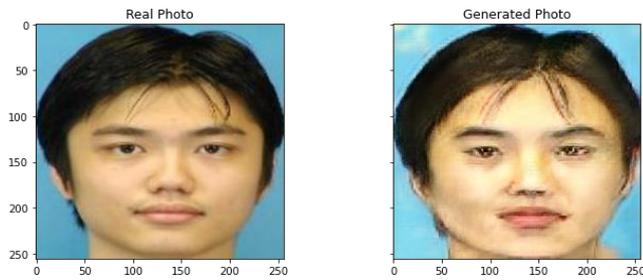
Gambar 19. Gambar perbandingan citra wajah asli dengan hasil citra *generated*.

Tabel 6. *Image quality metrics* dari gambar 18.

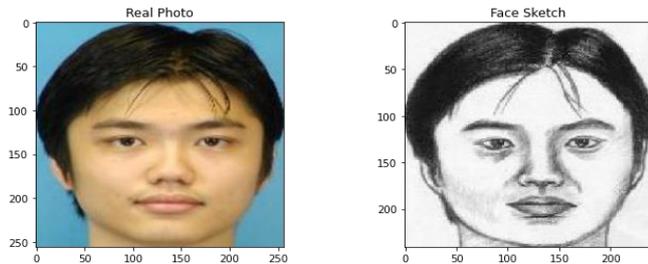
<i>Image Quality Metrics</i>	
MSE	3343.968475060691
PSNR	12.888181863508477
SSIM	0.577603486890371

tinggi, dikarenakan gambar tersebut memiliki perbedaan yang sangat jauh. PSNR yang dimiliki oleh citra wajah *generated* juga menunjukkan angka yang rendah, namun SSIM yang didapatkan memiliki nilai diatas 0.5.

Dalam pengaplikasian *face recognition*, tentu saja akan terlihat lebih baik prediksi model mengidentifikasi citra wajah *generated* terhadap sketsa wajah dibandingkan



Gambar 20. Gambar perbandingan citra wajah asli dengan hasil citra generated.



Gambar 21. Gambar perbandingan citra wajah asli dengan sketsa wajah. dengan citra wajah asli, dikarenakan tekstur yang dimiliki pada citra wajah generated lebih baik jika dibandingkan dengan sketsa wajah. Tabel 8 menunjukkan hasil face recognition sketsa wajah terhadap citra wajah asli (Gambar 20), dan Tabel 9 menunjukkan hasil face recognition pada citra wajah generated terhadap citra wajah asli (Gambar 21).

Dari percobaan yang telah dilakukan, maka dapat dibuktikan bahwa CycleGAN dapat membangkitkan citra wajah dari sketsa wajah, kemudian hasil tersebut dapat dibuktikan lebih akurat jika dilakukan implementasi face recognition.

V. KESIMPULAN

Dalam penelitian ini, telah diimplementasikan serangkaian proses dalam membangkitkan citra wajah menggunakan sketsa wajah dengan menggunakan CycleGAN. Berdasarkan hasil penelitian tersebut, metode CycleGAN dapat mengolah sketsa wajah menjadi citra wajah dengan baik. Dalam metode CycleGAN, diperlukan pre-processing sketsa wajah dan citra wajah dataset dengan baik, terlihat dari hasil testing dapat disimpulkan bahwa variasi yang rumit dalam sebuah data dapat menimbulkan kegagalan dalam GAN untuk melakukan image-to-image translation. Hal tersebut juga terpengaruh dikarenakan GAN melihat data input sebagai noise. Dalam merancang model, diperlukan keseragaman pada dataset seperti warna dan latar belakang, hal tersebut dibuktikan pada percobaan pada dataset CUFS yang berwarna dan custom dataset yang memiliki variasi data grayscale dan berwarna. Citra wajah yang dihasilkan oleh CycleGAN terbukti dapat meningkatkan performa dalam mengimplementasikan face recognition jika dibandingkan langsung dengan menggunakan sketsa wajah, hal tersebut dapat meningkatkan akurasi secara signifikan, hal tersebut dapat membantu sistem dalam mengidentifikasi wajah lebih akurat.

Demi pengembangan lebih lanjut mengenai penelitian ini, terdapat beberapa saran sebagai langkah berikutnya untuk memenuhi kekurangan dari penelitian yang telah dilakukan antara lain menggunakan dataset dengan tekstur warna yang seragam, meningkatkan epoch dalam proses training dan menambahkan fitur pengamatan jika model tidak dapat mempelajari lebih baik, makan proses training akan berhenti, mengimplementasikan auto-encoder dalam metode CycleGAN, dan mengembangkan media yang dapat mengimplementasikan model.

Tabel 7.

Image quality metrics dari gambar 19.

Image Quality Metrics	
MSE	1361.1170857747395
PSNR	16.791848752540513
SSIM	0.5139147506096932

Tabel 8.

Deepface summary dari gambar 20.

Deepface Summary	
Verified	True
Detector_backend	mtcnn
Model	VGC-Face
Distance	0.22789332412383712
Similiarity_metric	cosine
Threshold	0.4

Tabel 9.

Deepface summary dari gambar 21.

Deepface Summary	
Verified	True
Detector_backend	mtcnn
Model	VGC-Face
Distance	0.3943788177655929
Similiarity_metric	cosine
Threshold	0.4

DAFTAR PUSTAKA

- [1] E. P. Purwandari, A. Erlansari, A. Wijanarko, and E. A. Adrian, "Face sketch recognition using principal component analysis for forensics application," *J. Teknol. dan Sist. Komput.*, vol. 8, no. 3, pp. 178–184, 2020, doi: 10.14710/jtsiskom.2020.13422.
- [2] S. Klum, H. Han, A. K. Jain, and B. Klare, "Sketch Based Face Recognition: Forensic vs. Composite Sketches," in *2013 International Conference on Biometrics (ICB)*, 2013, pp. 1–8. doi: 10.1109/ICB.2013.6612993.
- [3] T. Ali, R. Veldhuis, and L. Spreeuwers, *Forensic Face Recognition: A Survey*. Netherlands: Centre for Telematics and Information Technology (CTIT), 2010.
- [4] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros, "Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks," in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2223–2232. doi: 10.1109/ICCV.2017.244.
- [5] N. M. Farid, M. S. Fard, and A. Nickabadi, "Face Sketch to Photo Translation using Generative Adversarial Networks," Amirkabir University of Technology, Tehran, 2021. doi: 10.48550/arXiv.2110.12290.
- [6] I. J. Goodfellow et al., "Generative Adversarial Networks," Universite de Montreal, 2014. doi: 10.48550/arXiv.1406.2661.
- [7] H. Huang, P. S. Yu, and C. Wang, "An Introduction to Image Synthesis with Generative Adversarial Nets," University of Illinois, Chicago, 2018. doi: 10.48550/arXiv.1803.04469.
- [8] Y. Fang, W. Deng, J. Du, and J. Hu, "Identity-aware CycleGAN for face photo-sketch synthesis and recognition," *Pattern Recognit.*, vol. 102, p. 107249, 2020, doi: 10.1016/j.patcog.2020.107249.
- [9] X. Wang and X. Tang, "Face photo-sketch synthesis and recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 31, no. 11, pp. 1955–1967, 2009, doi: 10.1109/TPAMI.2008.222.
- [10] W. Zhang, X. Wang, and X. Tang, "Coupled Information-Theoretic Encoding for Face Photo-Sketch Recognition," in *Conference on Computer Vision and Pattern Recognition (CVPR)*, 2011, pp. 513–520. doi: 10.1109/CVPR.2011.5995324.
- [11] S. I. Serengil and A. Ozpinar, "LightFace: A Hybrid Deep Face Recognition Framework," in *2020 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 2020, pp. 1–5. doi: 10.1109/ASYU50717.2020.9259802.