

## SINTESA CITRA DAUN KOPI MENGGUNAKAN *GENERATIVE ADVERSARIAL NETWORK* PADA DATASET PENYAKIT DAUN KOPI

Siti Khotimatul Wildah<sup>1\*</sup>; Abdul Latif<sup>2</sup>; Toto Haryanto<sup>3</sup>

Teknologi Komputer<sup>1</sup>, Sistem Informasi Kampus Kota Pontianak<sup>2</sup>, Ilmu Komputer<sup>1,3</sup>

Universitas Bina Sarana Informatika, Jakarta, Indonesia<sup>1</sup>

Universitas Bina Sarana Informatika, Pontianak, Indonesia<sup>2</sup>

IPB University, Bogor, Indonesia<sup>1,3</sup>

[www.bsi.ac.id](http://www.bsi.ac.id)<sup>1,2</sup>

[www.ipb.ac.id](http://www.ipb.ac.id)<sup>1,3</sup>

siti.ska@bsi.ac.id<sup>1\*</sup>; stkwildah@app.ipb.ac.id<sup>1</sup>; abdul.bll@bsi.ac.id<sup>2</sup>; totoharyanto@apps.ipb.ac.id<sup>3</sup>

(\*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

**Abstract**—Coffee, as the second most traded commodity after petroleum, faces production challenges, especially due to pest or disease attacks on coffee leaves. Therefore, it is important to carry out early detection of the disease in order to minimize the risk and apply special treatment. Automatic detection of disease can be done through the application of Computer Vision technology. However, one of the main challenges faced is the limited training dataset. Generative Adversarial Networks (GANs) is a Deep Learning method that is capable of modifying images with high quality. This research aims to synthesize coffee leaf images based on the public Coffee Leaf Disease dataset using the GANs method. Testing was carried out using the RMSProp optimizer, the learning rate was 0.0001 and was carried out for 300 epochs. The architecture built uses 26 layers in the generator model and 15 layers in the discriminator model. The results of the test show that the drilled network obtained an MMSE value of 0.1658, which is not too high because the resulting synthesized image is not very good.

**Keywords:** coffee leaf disease, computer vision, generative adversarial network, image synthesis.

**Abstrak**—Kopi, sebagai komoditas perdagangan kedua setelah minyak bumi, menghadapi tantangan produksi, terutama akibat serangan hama atau penyakit pada daun kopi. Oleh karena itu, penting untuk melakukan deteksi dini penyakit guna meminimalisir risiko dan menerapkan perawatan khusus. Deteksi otomatis penyakit dapat dilakukan melalui penerapan teknologi *Computer Vision*. Namun, salah satu tantangan utama yang dihadapi adalah keterbatasan dataset pelatihan. *Generative Adversarial Network* (GANs) merupakan salah satu metode *Deep Learning* yang mampu memodifikasi citra dengan kualitas tinggi. Penelitian ini bertujuan untuk melakukan sintesa citra daun kopi berdasarkan dataset publik Penyakit Daun Kopi menggunakan metode GANs. Pengujian dilakukan dengan menggunakan optimizer *RMSProp*, *learning rate* sebesar 0.0001 serta dilakukan sebanyak 300 *epoch*. Arsitektur yang dibangun menggunakan 26 lapisan pada model *generator* dan sebanyak 15 lapisan pada model *discriminator*. Hasil dari pengujian menunjukkan bahwa jaringan yang dilatih memperoleh nilai MMSE sebesar 0.1658 yaitu belum terlalu tinggi karena citra sintesa yang dihasilkan belum terlalu bagus.

**Kata kunci:** penyakit daun kopi, *computer vision*, *generative adversarial network*, sintesa citra.

### PENDAHULUAN

Kopi adalah jenis tanaman yang tumbuh dalam bentuk pohon yang menjadi bahan utama dalam pembuatan berbagai minuman kopi. Tanaman ini tersebar luas, dan saat ini Brasil terkenal sebagai produsen dan pengeksportir kopi

terbesar di dunia, memainkan peran penting dalam industri kopi global (Vartan, 2023). Namun, masalah umum yang sering terjadi dalam produksi kopi adalah adanya hama dan penyakit sehingga berdampak mengurangi pendapatan dan mengancam mata pencaharian ribuan keluarga di seluruh dunia (Cerda et al., 2020).

Salah satu faktor yang menyebabkan rendahnya kualitas kopi adalah adanya serangan hama dan penyakit, sehingga mengubah komposisi biji kopi dan kualitas minuman (Pereira et al., 2021). Tanaman kopi rentan terhadap berbagai penyakit. Jika proses identifikasi dan penanganannya terlambat, penyakit tersebut bisa menyebar dengan lebih luas dan menyebabkan kerugian (Ramadhan et al., 2021).

Pengenalan dini dan diagnosis hama atau penyakit pada tanaman kopi sangat penting untuk meminimalkan dampaknya terhadap kualitas dan hasil tanaman (Ayikpa et al., 2022). Baru-baru ini, *computer vision* dan teknik *machine learning* telah diterapkan dalam klasifikasi penyakit tanaman, mempercepat proses identifikasi serta memberikan alternatif yang handal dan efisien untuk mendeteksi penyakit (Wildah et al., 2022).

Namun model pembelajaran mesin saat ini cenderung membutuhkan dataset skala besar untuk memiliki kinerja yang baik. Akan tetapi, mengumpulkan dataset adalah proses yang mahal dan memakan waktu, sehingga data yang terbatas menjadi salah satu tantangan utama untuk mendapatkan akurasi pengenalan yang baik (Xu et al., 2022). Disisi lain saat ini telah berkembang metode *Generative Adversarial Network* (GAN) yang merupakan salah satu teknik dalam bidang *deep learning* yang memiliki kemampuan dalam *computer vision* meliputi peningkatan data, transfer domain, generasi sampel berkualitas tinggi, dan pemulihan gambar (Jin et al., 2020).

Metode ini terdiri dari dua jaringan saraf tiruan atau *neural networks* yang dikenal sebagai Generator dan Diskriminator. Dengan konfigurasi ini, GAN dapat menghasilkan data buatan yang menyerupai bentuk aslinya dari data yang digunakan sebagai input (Praramadhan & Saputra, 2021). Penelitian mengenai GAN telah dilakukan diantaranya yang dilakukan oleh Saman Motamed, Patrik Rogalla, dan Farzad Khalvati mengenai Augmentasi data menggunakan GANs untuk melakukan deteksi penyakit Pneumonia dan COVID-19 pada citra *rontgen* dada. Pada penelitian tersebut hasil menunjukkan bahwa penggunaan GANs untuk augmentasi data lebih baik dibandingkan dengan teknik augmentasi data lainnya seperti rotasi, zoom, dan lain sebagainya (Motamed et al., 2021).

Penelitian mengenai augmentasi data menggunakan GANs pada data konektivitas struktural otak pada sklerosis ganda yang dilakukan oleh Bernardino Barile, Aldo Marzullo, Claudio Stamile, dan Françoise Durand-Dubief Dominique Sappey-Marini, Hasil yang diberikan menunjukkan bahwa model generatif tersebut dapat

langsung diterapkan pada jaringan struktural otak. Secara kuantitatif maupun kualitatif, bahwa data yang baru dihasilkan tidak menunjukkan perbedaan signifikan dibandingkan dengan data nyata. Selain itu, penambahan sampel yang dihasilkan ke dalam dataset yang ada menghasilkan peningkatan kinerja klasifikasi (*F1-score* 81%) dibandingkan dengan pendekatan dasar sebelumnya (*F1-score* 66%) (Barile et al., 2021).

Kemudian penelitian yang dilakukan oleh Daiki Yorioka, Hyunho Kang dan Keiichi Iwamura, dimana pada penelitian ini dilakukan penerapan metode GANs untuk melakukan augmentasi data. Hasil yang diberikan yaitu kualitas dan akurasi hasil yang dicapai masih kurang memuaskan, akan menjadi keliru untuk mengabaikan potensi dari pendekatan ini. Tantangannya sekarang adalah untuk meningkatkan kualitas gambar yang dihasilkan, sehingga dapat meningkatkan akurasi dari CNN (Yorioka et al., 2020).

Selanjutnya penelitian mengenai penerapan metode DCGAN untuk melakukan augmentasi data pada citra tanah yang dilakukan oleh Patmawati, Andi Sunyoto, dan Emha Taufiq Luthfi. Penelitian ini menguji beberapa nilai latent space dimension dan hasil uji coba tersebut, nilai 100 memberikan hasil yang paling baik dalam menghasilkan citra sintesis yang mendekati aslinya (Patmawati et al., 2023).

Berdasarkan beberapa penelitian sebelumnya tersebut, maka pada penelitian ini menghadirkan inovasi dalam menerapkan metode *Generative Adversarial Network* (GAN) untuk menghasilkan citra sintesis daun kopi dengan menggunakan dataset citra hama dan penyakit pada tanaman kopi. Metode GAN, yang terdiri dari dua jaringan saraf tiruan (Generator dan Diskriminator), digunakan untuk menghasilkan citra sintetis yang menyerupai citra asli dari dataset yang digunakan sebagai input. Metode GANs memiliki potensi besar dalam menghasilkan citra sintetis berkualitas tinggi, yang dapat digunakan untuk memperluas dataset pelatihan, khususnya dalam konteks identifikasi penyakit pada tanaman.

Penelitian ini menjembatani celah antara keterbatasan dataset pelatihan dan kebutuhan akan lebih banyak data untuk meningkatkan keakuratan identifikasi penyakit tanaman kopi.

## BAHAN DAN METODE

Penelitian ini dilakukan dengan menggunakan metode *Generative Adversarial Network* (GANs). Tujuan dari penelitian ini adalah melakukan sintesa citra daun kopi pada dataset penyakit daun kopi.

**1. Sumber Data**

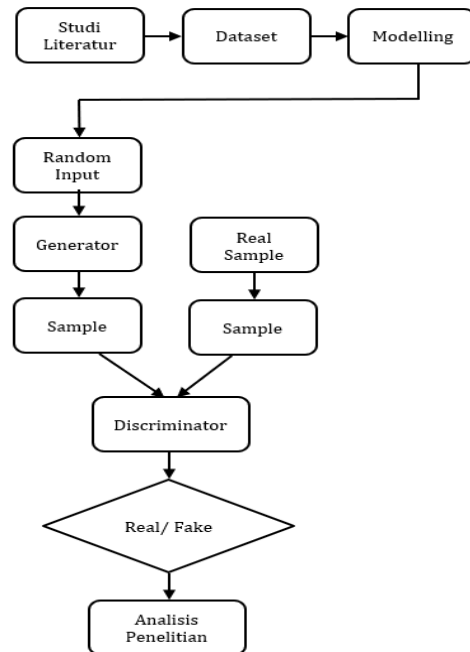
Pada penelitian ini, data yang digunakan berasal dari sumber publik yang diperoleh dari *repository kaggle* yang dipublikasikan oleh Brito Silva, Lucas, Cavalcante Carneiro, Álvaro Leandro, Silveira Almeida Renaud Faulin, Marisa. Data terdiri dari 2 kelas yaitu "*Rust (Hemileia vastatrix)*" dan *Leaf Miner (Leucoptera coffeella)* pada tanaman kopi (Kopi Arabika) (Brito Silva et al., 2020).

*Dataset* yang digunakan pada penelitian ini merupakan citra daun kopi yang terbagi dalam 2 kelas, diantaranya sebanyak 285 citra pada kelas *rust* (karat) dan 257 citra pada kelas *miner*. Citra dalam resolusi pengambilan asli sebesar 4000x2250 piksel. Diambil menggunakan kamera smartphone untuk menangkap citra, dan sebagian besar foto diambil di laboratorium dengan latar belakang putih. Citra berasal dari perkebunan kopi di Brazil.

**2. Alur Penelitian**

Pada proses metodologi penelitian, beberapa langkah atau urutan proses pengolahan dataset yang diuji dapat diamati mulai dari studi literatur, penggunaan dataset, tahap *modeling* menggunakan metode GANS dimana pada tahap ini metode GAN melibatkan penggunaan dua jaringan untuk menghasilkan sebuah citra. Jaringan pertama yang disebut generator bertanggung jawab untuk menciptakan citra yang realistis dari vektor input yang diterima dari data pelatihan. Generator pertama-tama dilatih agar mampu menciptakan citra yang tampak nyata. Setelah generator mampu menghasilkan citra, citra tersebut akan diteruskan ke jaringan kedua, yaitu *discriminator*. *Discriminator* dilatih untuk membedakan apakah citra yang diberikan oleh generator adalah asli atau palsu. Oleh karena itu, generator harus mampu menghasilkan citra yang dapat meyakinkan *discriminator* bahwa citra tersebut adalah citra asli (Kalendesang et al., 2022). Langkah berikutnya setelah pengujian menggunakan GANs adalah melakukan analisis mendalam terhadap hasil yang diperoleh. Proses ini melibatkan evaluasi secara rinci terhadap data yang dihasilkan, mengidentifikasi kekuatan dan kelemahan dari metode yang digunakan. Setelah analisis selesai, langkah selanjutnya adalah merangkum keseluruhan temuan dan pengetahuan yang diperoleh dari eksperimen tersebut ke dalam sebuah laporan yang menyajikan hasil-hasil yang signifikan dan kesimpulan akhir dari penerapan metode GANs dalam konteks yang relevan. Laporan ini kemudian dapat digunakan sebagai panduan atau acuan untuk pengembangan selanjutnya atau

penelitian yang terkait. Adapun alur penelitian dapat dilihat pada Gambar 1.




Sumber: (Hasil Penelitian, 2023)

Gambar 1. Alur Penelitian

Berdasarkan alur penelitian pada gambar 1, tahap pertama yaitu studi literatur yang mendukung untuk proses penelitian, identifikasi dan analisis masalah. Pada tahap ini dilakukan mengenai pola dan karakteristik dari citra yang digunakan, serta kebutuhan dari citra tersebut.

Tahap kedua dilakukan untuk melakukan pemanggilan dataset yang akan digunakan yang terdiri dari 2 kelas yaitu *Rust* dan *Miner*. Kelas citra *rust* memiliki ciri bercak kuning atau oranye pada permukaan atas dan bawah daun, mirip endapan debu. Sedangkan citra *miner* Jalur atau galeri putih atau cokelat di dalam daun karena aktivitas larva.



Sumber: (Carneiro et al., 2020)

Gambar 2. *Dataset* Penelitian

Selanjutnya, pada tahap ketiga dilakukan pemodelan menggunakan GANs, yang dimulai dengan tahap berikut:

- a. Dari Random Input ke Generator: Tahap awal dimulai dengan memasukkan input acak ke dalam generator GAN. Generator akan menghasilkan contoh atau citra sintetis berdasarkan input acak yang diberikan.
- b. Dari Citra Sintetis ke *Discriminator*: Citra sintetis yang dihasilkan oleh generator kemudian diperkenalkan ke *discriminator*. *Discriminator* mengevaluasi citra tersebut dan berusaha membedakan antara citra sintetis (hasil dari generator) dengan citra asli dari *dataset*.
- c. Dari *Real Sample* ke *Discriminator*: Di sisi lain, citra-citra asli dari *dataset* (yang disebut sebagai sampel nyata atau *real sample*) juga dimasukkan ke dalam *discriminator*.
- d. Keputusan Citra *Real* atau *Fake*: *Discriminator* akan memberikan keputusan berdasarkan penilaian yang dilakukannya terhadap citra-citra yang diberikan. Jika *discriminator* dapat membedakan citra sintetis dari citra asli dengan tingkat keberhasilan yang tinggi, maka hasilnya akan menghasilkan keputusan antara citra '*real*' (asli) dan '*fake*' (sintetis).

Proses ini terus berlanjut dalam siklus dimana generator berupaya untuk meningkatkan kemampuannya dalam membuat citra-citra sintetis yang semakin mendekati citra asli, sementara *discriminator* juga terus diperbarui untuk meningkatkan kemampuannya dalam membedakan antara citra-citra *real* dan *fake*.

Setelah proses penerapan model *Generative Adversarial Networks* (GANs) selesai, langkah selanjutnya adalah menganalisis hasil yang dihasilkan oleh model tersebut. Proses analisis ini bertujuan untuk mengevaluasi kualitas citra-citra sintetis yang telah dihasilkan.

## HASIL DAN PEMBAHASAN

Citra daun kopi yang digunakan dalam pelatihan memiliki 2 kelas yaitu *Rust* dan *Miner* dengan jumlah masing-masing kelas adalah 285 citra *rust* dan 257 citra *miner*, secara berturut-turut. Selain itu, jumlah tersebut digandakan untuk meningkatkan ukuran pelatihan. Semua citra daun kopi digunakan. Implementasi pelatihan ini dilakukan menggunakan *tools Jupyter Notebook* dengan pemrograman *python* dan *TensorFlow* untuk membuat, melatih, dan menerapkan model *deep learning*. Sementara *Keras* digunakan untuk membangun model *neural networks*.

Pada proses *modelling* bagian arsitektur generator dirancang dengan aturan seperti yang ditampilkan pada Tabel 1.

Tabel 1. Arsitektur Generator

Layer	Output Shape	Jumlah Parameters	Kernel Size	Fungsi Aktivasi
<i>Input</i>	<i>latent_dim</i> =100	-	-	-
<i>Dense</i>	128x128x3	491,52	-	-
<i>Reshape</i>	128,128,3	-	-	-
<i>Conv2D</i>	128,128,12 8	98,304	4x4/ <i>stri</i> <i>des</i> =1	
<i>Conv2D</i>	64,64,128	262,144	4x4/ <i>stri</i> <i>des</i> =2	
<i>Conv2D</i>	64,64,256	524,288	4x4/ <i>stri</i> <i>des</i> =1	
<i>Conv2D</i>	32,32,256	1,048,576	4x4/ <i>stri</i> <i>des</i> =2	
<i>Conv2D</i> <i>Transpose</i>	32,32,512	2,097,152	4x4/ <i>stri</i> <i>des</i> =1	<i>Leaky ReLU</i>
<i>Conv2D</i> <i>Transpose</i>	64,64,512	4,194,304	4x4/ <i>stri</i> <i>des</i> =2	
<i>Conv2D</i> <i>Transpose</i>	64,64,256	2,097,152	4x4/ <i>stri</i> <i>des</i> =1	
<i>Conv2D</i> <i>Transpose</i>	128,128,25 6	4,194,304	4x4/ <i>stri</i> <i>des</i> =2	
<i>Conv2D</i> <i>Transpose</i>	128,128,12 8	1,048,576	4x4/ <i>stri</i> <i>des</i> =2	
<i>Conv2D</i> <i>Transpose</i>	128,128,3	6,144	4x4/ <i>stri</i> <i>des</i> =1	<i>tanh</i>

Sumber: (Hasil Penelitian, 2023)

1. *Input layer*  
*Input layer* dengan jumlah neuron sebanyak 128\*128\*3 (ukuran gambar) tanpa penggunaan bias. Input dari layer ini adalah vektor ruang laten dengan ukuran 100.
2. *Reshape Layer*  
Layer ini mengubah output dari layer *Dense* sebelumnya menjadi bentuk yang diharapkan, yaitu sebesar 128, 128, 3, yang merepresentasikan dimensi citra berwarna dengan resolusi 128x128 piksel.
3. *Downsampling Layers*  
Beberapa layer *Conv2D* digunakan untuk melakukan *downsampling* atau pengurangan resolusi citra dengan tujuan untuk mengekstraksi fitur-fitur yang lebih tinggi. Pada penelitian ini layer konvolusi dengan 128 filter, kernel size 4x4, dan *padding* '*same*' agar ukuran output sama dengan ukuran input, dengan *stride* 1 seperti pada tahap pertama. Selanjutnya layer normalisasi *batch* untuk menstabilkan dan mempercepat proses training serta pada layer ini digunakan fungsi aktivasi *Leaky ReLU*.
4. *Upsampling Layers*  
Layer ini digunakan untuk melakukan *upsampling* atau peningkatan resolusi citra.

Pengaturan *Conv2Dtranspose* (512, 4, *strides=1, padding='same', kernel\_initializer='he\_normal', use\_bias=False*) merupakan Layer konvolusi transposisi dengan 512 filter, kernel size 4x4, dan *padding 'same'*, untuk melakukan *upsampling* dengan *stride 1*. Sedangkan pengaturan *Conv2Dtranspose* (512, 4, *strides=2, padding='same', kernel\_initializer='he\_normal', use\_bias=False*) merupakan Layer konvolusi transposisi untuk *upsampling* dengan *stride 2*. dan pengaturan *Conv2Dtranspose* (3,4,*strides = 1, padding = 'same', activation = 'tanh'*) merupakan Layer terakhir menggunakan aktivasi tanh yang menghasilkan citra sintetis dengan 3 channel (RGB) dan resolusi yang diinginkan.

5. *Layer Activation dan Normalization*

Pada beberapa lapisan, digunakan aktivasi *'LeakyReLU'* sebagai fungsi aktivasi dan *'BatchNormalization'* untuk mempercepat pelatihan dan menjaga stabilitas dalam model.

Sehingga arsitektur ini menggabungkan layer-layer konvolusi, konvolusi transposisi, fungsi aktivasi, dan normalisasi untuk membuat generator dalam model GANs yang dapat menghasilkan citra sintetis dari ruang laten yang diinisialisasi secara acak.

Arsitektur *discriminator* yang diberikan bertujuan untuk melakukan klasifikasi antara citra-citra yang dihasilkan oleh generator sebagai citra 'palsu' (*fake*) atau citra asli (*real*). Arsitektur *discriminator* dirancang dengan aturan seperti yang ditampilkan pada Tabel 2.

Tabel 2. Arsitektur *Discriminator*

Layer	Output Shape	Jumlah Parameters	Kernel Size	Fungsi Aktiva si
<i>Input</i>	( <i>SIZE, SIZE, 3</i> )	-	-	-
<i>Conv2D</i>	( <i>SIZE/2, SIZE/2, 128</i> )	6,144	4x4/ <i>strides =2</i>	
<i>Conv2D</i>	( <i>SIZE/4, SIZE/4, 128</i> )	131,072	4x4/ <i>strides =2</i>	
<i>Conv2D</i>	( <i>SIZE/8, SIZE/8, 256</i> )	524,288	4x4/ <i>strides =2</i>	<i>LeakyReLU</i>
<i>Conv2D</i>	( <i>SIZE/16, SIZE/16, 256</i> )	1,048,576	4x4/ <i>strides =2</i>	
<i>Conv2D</i>	( <i>SIZE/32, SIZE/32, 512</i> )	2,097,152	4x4/ <i>strides =2</i>	
<i>Flatten</i>	1	-	-	-
<i>Dense</i>	1	513	-	<i>sigmoid</i>

Sumber: (Hasil Penelitian, 2023)

1. *Input Layer*

Layer input digunakan untuk menentukan ukuran citra masukan dengan ukuran '*SIZE*' x '*SIZE*' dan 3 channel (RGB) yaitu sebesar 128 x 128 pixel.

2. *Convolutional Layers*

Beberapa layer '*Conv2D*' digunakan untuk mengekstraksi fitur-fitur dari citra input dengan penurunan resolusi. Pengaturan *Conv2D* (128,4, *strides=2, padding='same', kernel\_initializer='he\_normal', use\_bias=False*) merupakan layer konvolusi dengan 128 filter, kernel size 4x4, dan *padding 'same'*, melakukan konvolusi dengan langkah (*stride*) 2. Kemudian pengaturan layer normalisasi batch yang membantu dalam percepatan proses training dan stabilitas model serta digunakan fungsi aktivasi *Leaky ReLU*.

3. *Flatten Layer*

Mengubah output dari layer konvolusi menjadi vektor satu dimensi sebelum masuk ke layer *Dense*.

4. *Dense Layer*

Layer *Dense* dengan 1 neuron dan aktivasi sigmoid. Neuron ini menghasilkan output yang menentukan apakah citra yang dianalisis adalah '*real*' atau '*fake*'.


Sehingga, arsitektur ini memanfaatkan serangkaian layer konvolusi dan normalisasi untuk mengekstraksi fitur-fitur dari citra dan kemudian melakukan klasifikasi untuk membedakan antara citra '*real*' dan '*fake*'. Pada akhirnya, output yang dihasilkan adalah nilai probabilitas yang menunjukkan kepercayaan *discriminator* terhadap keaslian citra yang dianalisis.

Pengujian dilakukan dengan ketentuan *parameter* dan *hyperparameter* sebagai berikut:

1. *Parameter* yang digunakan yaitu ukuran citra sebesar 128x128 piksel. Ukuran *batch\_size* sebesar 8.

2. *Hyperparameters* yang digunakan yaitu ukuran Dimensi dari ruang laten (*latent space*) sebesar 100 yang digunakan untuk menghasilkan vektor noise acak. *Optimizer* yang digunakan adalah *RMSprop* dengan learning rate 0.0001, clip value 1.0, dan decay 1e-8 serta fungsi *loss Binary Cross Entropy* yang digunakan dalam pelatihan. Model dilatih selama 300 *epoch*.


Adapun hasil pengujian yang dilakukan dengan beberapa skenario penggunaan *epoch* diantaranya. Skenario pertama yang diujikan menggunakan arsitektur yang sama akan tetapi *hyperparameter* untuk *epoch* yang digunakan sebesar 50 *epoch*.



Sumber: (Hasil Penelitian, 2023)  
Gambar 3. Pengujian 50 Epoch

Pada Gambar 3 menggambarkan hasil dari pengujian selama 50 *epoch*. Gambar yang dihasilkan pada tahap ini belum menyerupai bentuk daun kopi, tetapi lebih cenderung memiliki bentuk bulat. Meskipun begitu, terdapat perkembangan yang mulai terlihat dalam pembentukan warna hijau yang mencerminkan warna daun pada gambar tersebut.

Pengujian selanjutnya dilakukan dengan penerapan 100 *epoch* yang menghasilkan citra seperti pada Gambar 4.




Sumber: (Hasil Penelitian, 2023)  
Gambar 4. Pengujian 100 Epoch

Gambar 4 menampilkan perkembangan dari hasil pengujian yang berlangsung selama 100 *epoch*. Pada tahap ini, terlihat bahwa gambar yang dihasilkan mulai menunjukkan kemiripan dengan bentuk daun kopi yang diinginkan. Meskipun demikian, terdapat beberapa area pada gambar yang masih memperlihatkan ketidakjelasan pada warna, menunjukkan bahwa proses pengembangan warna pada gambar masih belum optimal. Meskipun telah tercapai kemajuan dalam

menyerupai bentuk daun kopi, perlu dilakukan peningkatan lebih lanjut dalam reproduksi warna agar lebih mendekati aslinya.


Pengujian selanjutnya dilakukan dengan penerapan 150 *epoch* yang menghasilkan citra seperti pada Gambar 5.



Sumber: (Hasil Penelitian, 2023)  
Gambar 5. Pengujian 150 Epoch

Pada Gambar 5 menampilkan perkembangan dari hasil pengujian yang berlangsung selama 150 *epoch*. Pada tahap ini, gambar yang dihasilkan kurang lebih sama dengan yang telah dilakukan sebelumnya, perbedaan yang timbul tidak terlalu signifikan.

Pengujian selanjutnya dilakukan dengan penerapan 200 *epoch* yang menghasilkan citra seperti pada Gambar 6.



Sumber: (Hasil Penelitian, 2023)  
Gambar 6. Pengujian 200 Epoch

Pengujian berikutnya dilakukan sebanyak 200 *epoch* di mana gambar daun yang dihasilkan menunjukkan peningkatan dari pengujian sebelumnya. Bentuk daun yang terbentuk sudah menyerupai daun kopi asli, dan warna yang dihasilkan juga lebih baik karena lebih intens dan

jelas. Meskipun proses ini telah menunjukkan perkembangan yang signifikan, terdapat kekurangan dalam mereplikasi tekstur yang lebih detail dan jelas pada gambar daun yang dihasilkan.


Pengujian selanjutnya dilakukan dengan penerapan 300 epoch yang menghasilkan citra seperti pada Gambar 7.



Sumber: (Hasil Penelitian, 2023)  
 Gambar 7. Pengujian 300 Epoch

Dalam pengujian selanjutnya dengan 300 epoch yang ditampilkan pada gambar 7, terlihat peningkatan yang cukup signifikan dari hasil sebelumnya. Bentuk gambar daun yang dihasilkan sudah menyerupai daun kopi yang sebenarnya, dan intensitas serta kejelasan warnanya lebih baik dibanding pengujian sebelumnya. Namun demikian, perlu dicatat bahwa meskipun tekstur dari gambar daun yang terbentuk lebih baik daripada sebelumnya, namun masih belum mencapai tingkat detail yang diharapkan.

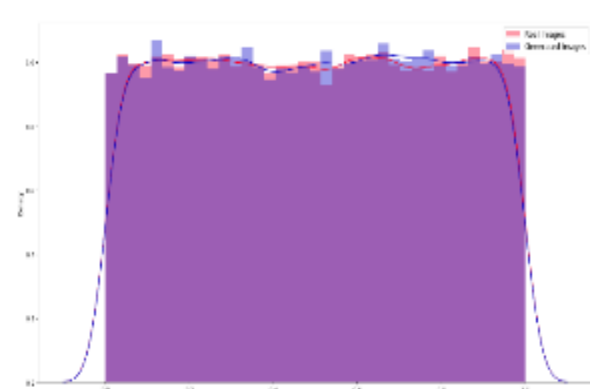
Pengujian selanjutnya dilakukan dengan penerapan 400 epoch yang menghasilkan citra seperti pada Gambar 8.



Sumber: (Hasil Penelitian, 2023)  
 Gambar 8. Pengujian 400 Epoch

Pada pengujian selanjutnya dengan 400 epoch, hasilnya tidak lebih baik dari pengujian sebelumnya pada 300 epoch. Gambar yang dihasilkan menunjukkan warna yang lebih kabur dan cenderung abu-abu. Hal ini menunjukkan adanya kemunduran dari pengujian sebelumnya.

Setelah dilakukan serangkaian pengujian dengan menggunakan metode GAN dengan optimizer *RMSProp* dan *learning rate* sebesar 0.0001. Metode tersebut diuji coba dengan 50 epoch, 100 epoch, 150 epoch, 200 epoch, 300 epoch, dan 400 epoch. Hasil menunjukkan bahwa penggunaan 300 epoch menghasilkan citra yang lebih baik dari pengujian lainnya dengan nilai MMSE sebesar 0.1658. Adapun grafik perbandingan antara *Real Image* dengan *Generated Image* yang dihasilkan ditampilkan pada Gambar 9.



Sumber: (Hasil Penelitian, 2023)  
 Gambar 9. Grafik Perbandingan *Real Image* dan *Generated Image*

Gambar 9 menunjukkan hasil yang baik dimana metode yang digunakan untuk menghasilkan citra baru yang hampir mendekati citra aslinya. Hal ini ditunjukkan dengan titik warna biru yang merupakan hasil generated image titiknya berdampingan dengan titik warna pink yang merupakan gambar asli.

**KESIMPULAN**

Pengujian yang dilakukan dengan menggunakan optimizer *RMSProp* dengan *learning rate* sebesar 0.0001 serta dilakukan sebanyak 300 epoch menghasilkan performa yang baik. Arsitektur yang dibangun pada penelitian yang diujikan terdiri dari 26 lapisan pada model generator dan sebanyak 15 lapisan pada model discriminator. Hasil dari pengujian menunjukkan bahwa jaringan yang dilatih memperoleh nilai MMSE sebesar 0.1658 yaitu belum terlalu tinggi karena citra sintesa yang dihasilkan belum sempurna. Adapun saran penelitian untuk dilakukan selanjutnya yaitu melakukan kolaborasi dengan ahli pertanian dan

peneliti di bidang penyakit tanaman sehingga dapat membantu dalam pengumpulan dan anotasi dataset yang lebih baik serta merancang arsitektur GAN untuk menghasilkan sintesa citra daun kopi yang lebih baik.

#### REFERENSI

- Ayikpa, K. J., Mamadou, D., Gouton, P., & Adou, K. J. (2022). Experimental Evaluation of Coffee Leaf Disease Classification and Recognition Based on Machine Learning and Deep Learning Algorithms. *Journal of Computer Science*, 18(12), 1201–1212. <https://doi.org/10.3844/jcssp.2022.1201.1212>
- Barile, B., Marzullo, A., Stamile, C., Durand-Dubief, F., & Sappey-Marinier, D. (2021). Data augmentation using generative adversarial neural networks on brain structural connectivity in multiple sclerosis. *Computer Methods and Programs in Biomedicine*, 206, 106113. <https://doi.org/10.1016/j.cmpb.2021.106113>
- Brito Silva, Lucas; Cavalcante Carneiro, Álvaro Leandro; Silveira Almeida Renaud Faulin, Marisa (2020), "rust (*Hemileia vastatrix*) and leaf miner (*Leucoptera coffeella*) in coffee crop (*Coffea arabica*).", *Mendeley Data*, V5, doi: 10.17632/vfx4trtcg.5
- Cerda, R., Avelino, J., Harvey, C. A., Gary, C., Tixier, P., & Allinne, C. (2020). Coffee agroforestry systems capable of reducing disease-induced yield and economic losses while providing multiple ecosystem services. *Crop Protection*, 134, 105149. <https://doi.org/10.1016/j.cropro.2020.105149>
- Jin, L., Tan, F., & Jiang, S. (2020). Generative Adversarial Network Technologies and Applications in Computer Vision. *Computational Intelligence and Neuroscience*, 2020(1). <https://doi.org/10.1155/2020/1459107>
- Kalendesang, R. R., Liliana, L., & Setiabudi, D. H. (2022). Pewarnaan Otomatis Sketsa Gambar Menggunakan Metode Conditional GAN Untuk Mempercepat Proses Pewarnaan. *Jurnal Infra*, 10(2), 233-239.
- Motamed, S., Rogalla, P., & Khalvati, F. (2021). Data augmentation using Generative Adversarial Networks (GANs) for GAN-based detection of Pneumonia and COVID-19 in chest X-ray images. *Informatics in Medicine Unlocked*, 27(August), 100779. <https://doi.org/10.1016/j.imu.2021.100779>
- Patmawati, Andi Sunyoto, & Emha Taufiq Luthfi. (2023). Augmentasi Data Menggunakan Dcgan Pada Gambar Tanah. *TEKNIMEDIA: Teknologi Informasi Dan Multimedia*, 4(1), 45–42. <https://doi.org/10.46764/teknimedia.v4i1.100>
- Pereira, D. R., Nadaleti, D. H. S., Rodrigues, E. C., da Silva, A. D., Malta, M. R., de Carvalho, S. P., & Carvalho, G. R. (2021). Genetic and chemical control of coffee rust (*Hemileia vastatrix* Berk et Br.): impacts on coffee (*Coffea arabica* L.) quality. *Journal of the Science of Food and Agriculture*, 101(7), 2836–2845. <https://doi.org/10.1002/jsfa.10914>
- Praramadhan, A. A., & Saputra, G. E. (2021). Cycle Generative Adversarial Networks Algorithm With Style Transfer For Image Generation. *arXiv preprint arXiv:2101.03921*. 1–12. <http://arxiv.org/abs/2101.03921>
- Ramadhan, M., Anwar, B., Gunawan, R., & Kustini, R. (2021). Sistem Pakar Untuk Mendiagnosa Penyakit Pada Tanaman Kopi Menggunakan Metode Teorema Bayes. *Journal of Science and Social Research*, 4307(June), 115–121.
- Vartan, J. (2023). Coffee Cultivation and Industry in Brazil: A Comprehensive Review. *International Journal of Science and Society*, 5(3), 323–332. <https://doi.org/10.54783/ijssoc.v5i3.751>
- Wildah, S. K., Agustiani, S., Latif, A., Pebrianto, R., Hasan, F. N., & Indriyani, F. (2022). In 2022 International Conference on Information Technology Research and Innovation (ICITRI) (pp. 179-183). *IEEE*. <https://doi.org/10.1109/ICITRI56423.2022.9970214>
- Xu, M., Yoon, S., Jeong, Y., & Park, D. S. (2022). Transfer learning for versatile plant disease recognition with limited data. *Frontiers in Plant Science*, 13(November), 1–14. <https://doi.org/10.3389/fpls.2022.1010981>
- Yorioka, D., Kang, H., & Iwamura, K. (2020). Data Augmentation for Deep Learning Using Generative Adversarial Networks. *2020 IEEE 9th Global Conference on Consumer Electronics, GCCE 2020*, 516–518. <https://doi.org/10.1109/GCCE50665.2020.9291963>