

# AUGMENTASI DATA MENGGUNAKAN DCGAN PADA GAMBAR TANAH

(DATA AUGMENTATION USING DCGAN FOR SOIL IMAGE)

Patmawati<sup>1)</sup>, Andi Sunyoto<sup>2)</sup>, dan Emha Taufiq Luthfi<sup>3)</sup>

<sup>1, 2,3)</sup>Teknik Informatika dan Universitas Amikom Yogyakarta

Yogyakarta

Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta  
55281

e-mail: [patmawati@students.amikom.ac.id](mailto:patmawati@students.amikom.ac.id)<sup>1)</sup>, [andi@amikom.ac.id](mailto:andi@amikom.ac.id)<sup>2)</sup>, [emhataufiquluthfi@amikom.ac.id](mailto:emhataufiquluthfi@amikom.ac.id)<sup>3)</sup>

## ABSTRAK

Beberapa penelitian terkait klasifikasi jenis tanah telah banyak dilakukan. Namun, masing-masing penelitian tersebut menggunakan dataset yang berbeda. Hanya sebagian kecil peneliti yang membagikan dataset citra tanah secara public. Selain itu, dataset yang dipublish memiliki ketidakseimbangan jumlah data pada setiap kelasnya yang akan menghasilkan performa model yang buruk atau over fit, khususnya deep learning. Untuk menangani masalah tersebut digunakan proses augmentasi data sintesis dengan menggunakan model DCGAN. Jaringan generator yang terdapat pada model DCGAN memiliki inputan latent space dimension yang nilainya dapat bervariasi. Ukuran latent space dimension sangat penting dalam memungkinkan rekonstruksi data atau citra saat proses pelatihan. Penelitian ini, melakukan uji coba nilai latent space dimension pada jaringan generator. Nilai latent space yang digunakan pada percobaan ini yaitu 64, 100, 128, 256 dan 512. Untuk menguji efek dimensi ruang laten pada citra digunakan metode evaluasi secara kuantitatif, yaitu Fréchet Inception Distance (FID). Score terkecil dari FID menunjukkan model GAN yang lebih baik dalam menghasilkan citra sintesis. Dari hasil evaluasi didapatkan score terkecil bernilai 267,39 dengan menggunakan inputan latent space dimension yang bernilai 100.

**Kata Kunci:** Deep Convolutional Generative Adversarial Networks (DCGAN), Latent space dimension, Fréchet Inception Distance (FID), Gambar Sintesis.

## ABSTRACT

Several studies related to soil type classification have been conducted. However, each of these studies uses different datasets. Only a small number of researchers share soil image datasets publicly. In addition, the published dataset has an imbalance in the amount of data in each class which will result in poor model performance or over fit, especially deep learning. To handle this problem, a synthetic data augmentation process is used using the DCGAN model. The generator network contained in the DCGAN model has a latent space dimension input whose value can vary. The size of the latent space dimension is very important in enabling data or image reconstruction during the training process. This research tests the latent space dimension value on the generator network. The latent space values used in this experiment are 64, 100, 128, 256 and 512. To test the effect of latent space dimension on the image, a quantitative evaluation method, namely Fréchet Inception Distance (FID), is used. The smallest score of FID indicates a better GAN model in producing synthesized images. From the evaluation results, the smallest score is 267.39 by using latent space dimension input which is 100

**Keywords:** Deep Convolutional Generative Adversarial Networks (DCGAN), Latent space dimension, Evaluation, Fréchet Inception Distance (FID), Image synthesis.

## I. PENDAHULUAN

Pemanfaatan dari Artificial Intelligence serta Machine Learning dalam image processing dapat membantu dalam mendeteksi atau mengklasifikasi jenis tanah [1]. Beberapa penelitian terkait klasifikasi jenis tanah menggunakan machine learning ataupun deep learning telah banyak dilakukan oleh para peneliti sebelumnya.

Penelitian yang dilakukan [2] yaitu, klasifikasi jenis tanah menggunakan teknis machine learning, diantaranya Decision Tree, K-Nearest Network (KNN), Support Vector Machine (SVM) dan ANN. Pada penelitian berikut [3] yang melakukan penelitian untuk menangani multi class dalam klasifikasi jenis tanah dengan menggunakan metode SVM. Selanjutnya [4] yang melakukan klasifikasi jenis tanah menggunakan DT, ANN dan SVM berdasarkan segmentation warna tanah. Penelitian [1]

yang melakukan klasifikasi citra tanah menggunakan enam model DCNN, yaitu Rest-Net152V2, VGG-16, VGG-19, Inception-ResNetV2, Exception dan DenseNet201. Performa akurasi dari model yang dihasilkan rata-rata mencapai 98.46%. Masing-masing penelitian tersebut menggunakan dataset yang berbeda dengan model pengambilan data yang juga berbeda. Hanya sebagian kecil peneliti yang membagikan dataset citra tanah secara publik. Terbatasnya dataset tersebut dapat mengakibatkan terjadinya ketidakseimbangan jumlah data pada setiap kelasnya yang akan menghasilkan performa model, khususnya *deep learning*, menjadi buruk atau *overfitting* [5]. Dengan *augmentation data*, variasi data baru dapat terbentuk sehingga dapat menangani masalah keterbatasan jumlah dataset.

Salah satu model augmentasi modern adalah dengan membuat citra sintesis berkualitas tinggi. Citra sintesis dianggap sebagai cara efektif untuk melengkapi dataset yang akan digunakan dalam proses *training* model (Zhu et al. 2018). Citra sintesis dapat dibentuk dengan menggunakan model inovatif yaitu *Generative Adversial Network* (GAN) (Waheed et al. 2020). GAN telah diimplementasi di beberapa penelitian dalam proses menghasilkan citra sintesis berkualitas tinggi yang digunakan untuk proses *training* model.

Saat ini model GAN telah mengalami perkembangan dan kombinasi teknik sehingga menghasilkan model GAN yang baru, salah satu diantaranya yaitu *Deep Convolutional Generative Adversial Network* (DCGAN). DCGAN merupakan model yang baik dalam meningkatkan stabilitas pelatihan GAN dan kualitas hasil citra (Ma et al. 2020).

Gambar yang dihasilkan oleh jaringan generator merupakan gambar fotorealistik baru yang ditransformasikan berdasarkan pemetaan *latent vector* yang teracak dan berada pada ruang latent  $n$ -dimensi. [6]. Transformasi gambar yang bermakna dihasilkan dari *latent vector* melalui operasi aritmatika dalam *latent space dimension* [7]. Penelitian sebelumnya [8], menganalisis dampak pemilihan nilai  $k$  latent space dimension *autoencoder* terhadap performa akhirnya. Pada penelitian sebelumnya, *latent space dimension* diatur pada nilai 64, 100, 128 serta 512. Ukuran *latent space dimension* sangat penting dalam memungkinkan rekonstruksi data pelatihan yang akurat [9].

Untuk menguji efek dimensi ruang laten pada citra yang dihasilkan oleh generator dibutuhkan evaluasi GAN dengan menggunakan metode yang efisien dan objektif, yaitu metode evaluasi kuantitatif [6]. Terdapat dua metrik evaluasi GAN secara kuantitatif, salah satunya adalah *Fre'chet Inception Distance* (FID). Metrik tersebut melakukan perhitungan terhadap kemiripan gambar yang dihasilkan dan gambar asli dari data *training* [10].

Berdasarkan penjelasan diatas, maka pada penelitian ini, peneliti mencoba melakukan riset pembuatan citra sintesis menggunakan model DCGAN dengan percobaan pengubahan nilai parameter pada *latent space dimension* untuk mengetahui pengaruhnya terhadap kualitas gambar yang dihasilkan. Diharapkan dengan adanya penelitian ini, dapat membantu dalam pembuatan dataset citra yang memiliki kualitas citra terbaik untuk menangani masalah ketersediaan dataset atau imbalanced dataset.

## II. STUDI PUSTAKA

Penelitian terkait pembuatan citra sintesis menggunakan model DCGAN telah banyak dilakukan. Seperti penelitian (Venu and Ravula 2021) yang melakukan evaluasi terhadap model DCGAN dalam proses augmentasi dataset *medical*. Penelitian tersebut dilakukan untuk menangani *imbalanced* pada dataset yang dapat mengakibatkan *over fitting* pada saat proses *training model* menggunakan *deep learning*. Dataset yang digunakan adalah citra rotgen dada yang terdiri atas dua kategori, yaitu Normal dan Pneumonia. Dataset tersedia sebanyak 5216 citra. Ukuran citra yang digunakan adalah 128 x 128 dengan *latent space dimension* sebesar 100. Layer pada *Generator* dan *Discriminator* menggunakan empat layer *convolutional*. Jumlah citra sintensis yang dihasilkan tidak dipaparkan dalam penelitian. Citra *x-ray* meningkat menjadi lebih baik pada *epoch* 500. Evaluasi model DCGAN menggunakan metode *Fréchet Distance of Inception* (FID) dengan *score* mencapai 1.289, dimana semakin kecil nilai *score* FID maka semakin baik citra tersebut.

Selanjutnya penelitian yang dilakukan oleh (Yuwana et al. 2020) yang melakukan klasifikasi citra penyakit daun tea dengan melakukan proses augmentasi data menggunakan model GAN dan DCGAN (Yuwana et al. 2020). Dataset terdiri atas 4 kategori yaitu Daun tea Sehat, Blister Blight, Empoasca, dan Looper Caterpillar. Skenario

penelitian, yaitu peneliti melakukan *trainig model* GAN dengan *epoch* 1000 dan 2000. Hal yang sama dilakukan juga menggunakan model DCGAN. Pada model GAN dan DCGAN yang dibuat, *image size* yang digunakan adalah 64x64 pixel, dengan *optimizer Adam* serta *learning rate* = 1e-5. Penelitian ini melakukan dua kali percobaan dengan mengubah nilai *epoch*. Citra yang dihasilkan sebanyak 1000 citra untuk setiap kategori dengan *epoch* 1000 dan 2000 pada setiap kategori citra untuk *epoch* 2000. Sehingga tidak terdapat proses *balance* data, hanya terjadi proses penambahan data.

Penelitian terkait DCGAN juga dilakukan oleh (Smaida et al.) yang mencoba meningkatkan akurasi citra penyakit mata dengan menggunakan proses augmentasi DCGAN (Smaida, Yaroshchak, and El Barg 2021). Dataset terdiri atas 4 kategori penyakit mata, yaitu *Glaucoma*, *Diabetic retinopathy*, *Myopia*, dan *Normal*. Citra sintesis yang dihasilkan hanya digunakan untuk penambahan data training. Penelitian ini memperkenalkan GMD model yang digunakan untuk mengevaluasi data pelatihan, pengujian dan validasi menggunakan ukuran akurasi. Citra sintesis yang disimpan untuk menjadi dataset adalah gambar yang memiliki nilai  $D(G(z))$  antara 0.76 hingga 1.

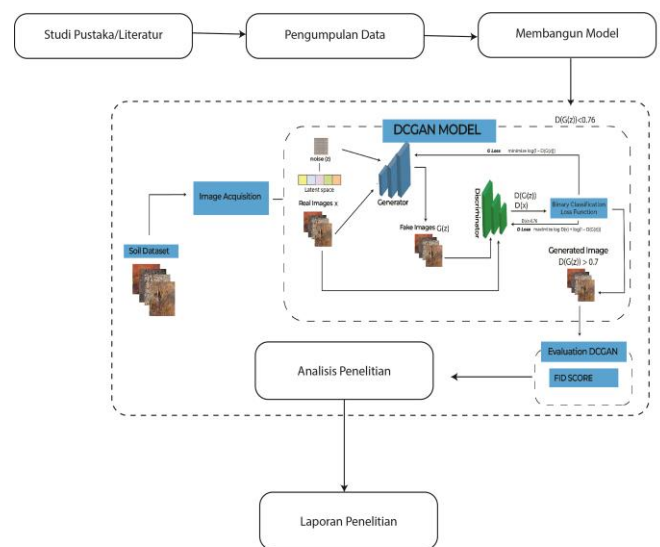
Berbeda dengan penelitian sebelumnya, Ma et al. melakukan augmentasi data menggunakan model DCGAN untuk mengatasi *unbalance* dataset sel darah (Ma et al. 2020). Hanya saja, dalam penelitian, citra sintesis hasil augmentasi hanya ditambahkan untuk proses *training* saja. Kemudian, terdapat adanya proses *pre-processing* data yaitu berupa operasi *transformation* seperti *flipping*, *clipping* dan *scaling* pada citra yang dilakukan sebelum diproses menggunakan model DCGAN. Model klasifikasi yang digunakan adalah *Convolutional Neural Network* (CNN) arsitektur ResNet dengan parameter *epoch* 30. Kesimpulan yang didapatkan adalah terjadi peningkatan hasil akurasi klasifikasi citra.

Penelitian yang dilakukan (Frid-Adar et al. 2018) melakukan penelitian menggunakan model DCGAN untuk meningkat akurasi klasifikasi citra serta menambah jumlah dataset (Frid-Adar et al. 2018). Dataset yang digunakan hanya terdiri atas 182 dengan 3 kategori citra hati lesion, yaitu *Cyst*, *Met* dan *Hem*. Jumlah citra pada Dataset setelah adanya proses augmentasi menjadi 302 citra. Jumlah tersebut masih dianggap sedikit untuk proses klasifikasi menggunakan *deep learning*. Data penambahan data juga dilakukan hanya untuk


*training* data. Performa model yang dibuat diukur dengan menggunakan nilai *Sensitivity* dan *Specificity*.

### III. METODE PENELITIAN

Alur penelitian dapat dilihat pada Gambar 1. yang dimulai dari studi pustaka atau literatur terhadap penelitian-penelitian lainnya yang berkaitan dengan model DCGAN. Selanjutnya, dataset dikumpulkan untuk proses pembuatan citra sintesis. Dataset yang digunakan adalah dataset yang telah digunakan pada penelitian sebelumnya [1]. Dataset terdiri atas 4 kategori yaitu alluvial, black soil, clay soil dan red soil



Gambar 1 Alur Penelitian




Gambar 2 Dataset Penelitian

Gambar 2, diatas adalah dataset untuk penelitian ini. Setelah dataset terkumpul, sebelumnya dataset terlebih dahulu di *preprocessing*,

untuk disamakan file ekstensi citra yang terdapat didalam dataset.

Proses pembangun model dilakukan setelah preprocessing dataset selesai. Model DCGAN yang dibangun menggunakan arsitektur *generator* dan *discriminator* yang telah ditentukan oleh peneliti dalam penelitian ini.



Gambar 3 Arsitektur DCGAN

Pada Gambar 3, diatas adalah arsitektur DCGAN yang terdiri dari jaringan *generator* dan *discriminator*. Pada jaringan *generator* menggunakan layer *convolutional transpose* (*Conv2dTranpose*) yang terdiri atas empat layer *Conv2DTransposes* dengan aktivasi *Rectified Linear Unit (ReLU)* untuk setiap layer kecuali pada layer terakhir menggunakan fungsi *tanh*. Untuk detail parameter yang digunakan pada jaringan *generator* dapat dilihat pada Tabel 1. Arsitektur Generator. Inputan dim latent vector yang digunakan adalah 64,100,128,256, dan 512

Tabel 1 Arsitektur Generator  
 $n \in \{64,100,128,256,512\}$

Generator		
Input	n-dim latent vector z	
Dense	16 x 16 x 256	ReLU
Reshape	(16,16,256)	
Conv2DTranpose	256 4x4 filters, stide 2	ReLU
Conv2DTranpose	512 4x4 filters, stide 2	ReLU
Conv2DTranpose	1024 4x4 filters, stide 2	ReLU
Conv2DTranpose	3 5x5 filters, stride 2	tanh
Output	128x128x3	

Sedangkan jaringan *discriminator*, layer yang digunakan adalah *convolution Conv2D* yang terdiri atas tiga layer dengan aktivasi *LeakyReLU* pada setiap layernya dan layer terakhir menggunakan fungsi *sigmoid*. *Optimizer* yang digunakan adalah *Adam* dengan *learning rate* sebesar 0.0002, *beta\_1* =0,5 serta *batch size*= 32. Untuk Ukuran gambar,

peneliti mencoba melakukan pengujian dengan ukuran 128x128x3 dengan epoch percobaan yaitu 1000. Untuk detail parameter serta arsitektur jaringan *discriminator* dapat dilihat pada Tabel 2 arsitektur *discrimantor*

Tabel 2 Arsitektur Disrcriminator

Discriminator		
Input	128x128x3	
Conv2D	128 4x4 filters, stide 2	ReLU
Conv2D	512 4x4 filters, stide 2	ReLU
Conv2D	512 4x4 filters, stide 2	ReLU
FLATTEN		
DROPOUT (0.3)		
Dense	1	Sigmoid

Dataset kemudian dimasukan kedalam model DCGAN untuk diproses sehingga menghasilkan citra sintesis ( $D(G(z))$ ). Nilai ( $D(G(z))$ ) yang dijadikan sebagai dataset > 0.7 hingga 1. Selanjutnya citra sintesis yang telah diberhasil dibuat, dievaluasi menggunakan perhitungan FID Score.

Fréchet Distance of Inception (FID) adalah salah satu model evaluasi GAN yang banyak digunakan [13]. Fréchet Distance of Inception (FID) merupakan pengukuran evaluasi kinerja GAN berdasarkan kualitas citra dengan membandingkan kesamaan citra antara citra yang berhasil dibuat terhadap citra asli [10]. FID Score menggunakan arsitektur *InceptionV3*, dimana layer *pooling* terakhir digunakan untuk menangkap features spesifik dari inputan citra. Fungsi aktivasi pada setiap citra nyata dan citra yang nyata menghasilkan jarak distribution *Gaussian Multivariate* dan jarak distribusi citra tersebut akan dihitung menggunakan Fréchet Distance, yang kemudian disebut persamaan *Wassertein-2 distance*. Score terkecil dari FID menunjukkan model GAN yang lebih baik [14]. Penelitian ini menghitung Fréchet Distance of Inception (FID) score menggunakan library python yang telah disediakan [15]. Hasilnya akan dianalisis untuk dilaporkan dalam penelitian ini

#### IV. HASIL DAN PEMBAHASAN

##### A. Dataset

Citra yang terdapat pada dataset digunakan untuk membuat citra sintesis baru dengan menambahkan



jumlah data pada dataset tanah sebelumnya. Dataset yang semulanya berjumlah 903, ditambah hingga menjadi 2000 citra dengan jumlah penambahan citra pada setiap kategori adalah sebagai berikut:

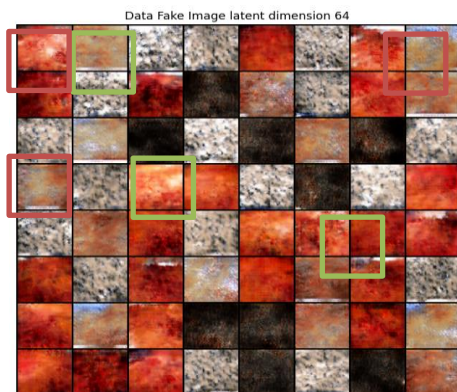
Tabel 3. Hasil Augmentasi Data

No	Citra	Awal	DCGAN	Total
1	Black Soil	259	241	500
2	Red Soil	230	270	500
3	Clay Soil	191	309	500
4	Alluvial Soil	223	277	500
5	Total	903	1097	2000


Pada Tabel 3 diatas, penambahan citra sebanyak 1097 dari total citra awal yang tebagi atas 241 citra sintesis Black Soil, 270 citra sintesis kategori Red Soil, 309 citra sintesis kategori Clay Soil dan 277 citra sintesis kategori Alluvial Soil. Total citra keseluruhan setelah ditambahkan citra sintesis adalah 2000 dimana masing-masing kategori terdiri atas 500 citra. Citra sintesis yang disimpan dalam dataset adalah citra yang memiliki nilai  $D(G(z))$  antara 0.76 hingga 1.

#### B. Augmentasi Data

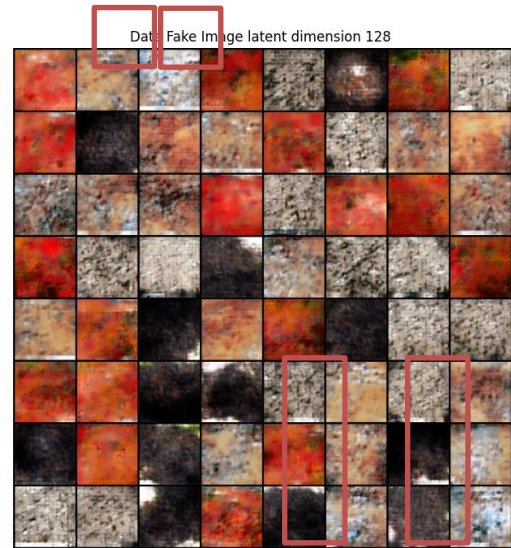
Proses augmentasi data menggunakan model DCGAN dilakukan dengan melakukan perubahan terhadap nilai parameter *latent space dimension*. Ukuran citra yang digunakan pada penelitian ini yaitu 128x128. Nilai parameter *latent space dimension* yang digunakan yaitu 64, 100, 128, 256 dan 512. Berikut Gambar 4. adalah Hasil Augmentasi menggunakan model DCGAN dengan variasi *latent space dimension*  $n \in \{64, 100, 128, 256, 512\}$




Gambar 4 a Hasil Citra Sintesis  $n \in 64$




Gambar 4 b Hasil Citra Sintesis  $n \in 100$



Gambar 4 c Hasil Citra Sintesis  $n \in 128$



Gambar 4.d Hasil Citra Sintesis  $n \in 256$



Gambar 4 e Hasil Citra Sintesis  $n = 512$ 

Pada Gambar 4 (a), (b), (c) dan (d) diatas merupakan citra dataset yang menggunakan inputan citra berukuran 128x128. Gambar 4. (a) merupakan citra sintesis yang nilai parameter latent space dimensionnya 64. Pada gambar tersebut tampak citra terlihat masih blur secara keseluruhan. Pada citra kategori Clay\_Soil yang diberi kotak hijau, tekstur tanahnya masih belum jelas. Masih banyak area yang berwarna putih. Sama halnya dengan citra kategori Alluvial\_Soil yang diberi tanda kotak merah, masih terdapat area pada citra yang berwarna putih dan warna dominan citra tanah tidak terlalu nampak.

Sedangkan pada Gambar 4 (b) nilai parameter latent space yang digunakan adalah 100. Pada Gambar 4 (b), terlihat citra kategori Alluvial Soil yang diberi tanda kotak merah, masih terlihat belum menyerupai permukaan citra alluvial soil dan nampak blur. Namun bila dibandingkan dengan hasil citra alluvial soil menggunakan latency 64, citra alluvial soil menggunakan latent dimension 100 lebih baik. Sudah nampak ada penggabungan atau perpaduan citra.

Selanjutnya pada Gambar 4 (c) nilai parameter latent dimensi yang digunakan adalah 128. Setiap citra dengan kategori berbeda terlihat lebih baik bila dibandingkan dengan citra pada Gambar 4.1 (b). khususnya untuk kategori Alluvial soil yang ditandai dengan kotak merah. Perwarnaan pada hasil citra sintesis tersebut terlihat telah terkombinasi dengan baik serta efek blur pada citra sudah berkurang bila dibandingkan dengan citra sintesis menggunakan latent dimensi 64 dan 100.

Pada Gambar 4 (d) citra sintesis tanah yang dibuat dengan menggunakan nilai latent space dimension adalah 256, terlihat seperti tidak ada perbedaan antara jenis tanah red (diberi tanda kotak merah) dengan jenis tanah alluvial (diberi tanda kota hijau). Warna dominan merah orange pada tanah red tidak begitu nampak pada hasil citra. Citra sintesis kategori Alluvial (ditandai dengan kotak hijau) memiliki banyak pixel yang blur,

sehingga tidak terlihat seperti permukaan tanah. Dan juga warna hitam pada citra kategori black juga tidak begitu gelap bila dibandingkan dengan citra tanah kategori black yang menggunakan nilai latentspace dimension 64, 100 dan 128. Sebagian citra jenis clay yang diberi tanda kotak biru, masih memiliki ruang pixel yang berwarna putih.

Terakhir, pada gambar 4 (e), citra sintesis tanah yang dibuat dengan menggunakan nilai latent space dimession yaitu 512. Pada gambar tersebut, citra sintesis kategori black soil terlihat berbeda. Pada citra tersebut, terlihat ada kotak-kotak pixel seperti pattern yang tidak menyatu. Dan gambarnya terlihat blur. Hal tersebut juga terlihat pada hasil citra kategori alluvial soil dan red soil.

Keempat dataset citra sintesis yang berhasil dibuat dengan perbedaan latent space dimension tersebut, kemudian dievaluasi dengan menggunakan metrik perhitungan Fre'chet Inception Distance (FID). Tujuannya yaitu untuk mengetahui efektivitas latent space terhadap kualitas gambar yang dihasilkan menggunakan model DCGAN. Metrik FID melakukan perhitungan terhadap kemiripan gambar yang dihasilkan dan gambar asli [10]. Score terkecil dari FID menunjukkan bahwa model GAN yang lebih baik [14] dalam menghasilkan citra.

Pada penelitian ini, peneliti melakukan dua kali percobaan untuk menghitung score FID yaitu, percobaan pertama, dengan menghitung score FID pada setiap kategori citra tanah dengan latent space dimension yang berbeda-beda. Percobaan kedua, dengan menghitung score FID berdasarkan latent space dimension yang digunakan.

Untuk percobaan pertama, hasil score FID citra sintesis tiap kategori dapat dilihat pada Tabel 4. dibawah ini.


Tabel 4 Hasil Score FID Per Kategori  $n \in \{64, 100, 128, 256, 512\}$ 

Kategori	Latent space dimensi ( $n$ )				
	64	100	128	256	512
Alluvial Soil	360,66	322,0	370,01	344,54	385,67
Clay Soil	344,48	332,84	340,64	381,50	322,08
Black Soil	401,59	374,96	360,80	359,24	383,60
Red Soil	315,12	327,34	442,48	344,68	256,67

Berdasarkan Tabel 4. diatas, untuk latent space dimension bernilai 64, diketahui score tertinggi dimulai dari black soil, alluvial soil, clay soil dan red soil. Padahal jika dilihat kembali pada Gambar 4. (a), citra sintesis yang terlihat kurang bagus adalah alluvial soil dan clay soil. Sedangkan black soil masih terlihat sesuai dengan citra aslinya.

Untuk latent space dimension 100, nilai score FID yang didapatkan dimulai dari tertinggi yaitu, black soil, clay soil, red soil dan terakhir alluvial soil. Sedangkan jika dilihat kembali pada Gambar 4. (b), hanya citra kategori alluvial saja yang terlihat blur sekali dan kombinasi atau perpaduan gambar belum terlihat baik. Selanjutnya latent space dimension 128. Untuk latent space tersebut, didapatkan score FID tertinggi mulai dari red soil, alluvial soil, black soil dan clay soil. Pada Gambar 4. (c), citra yang masih terlihat kurang bagus dalam perpaduan gambarnya adalah citra alluvial soil. Berikutnya adalah hasil score FID menggunakan latent space dimension 256. Pada tabel 4.2 diatas, diketahui bahwa nilai FID score tertinggi dimulai dari clay soil, black soil, alluvial soil dan red soil. Nilai threshold antara alluvial soil dan red soil tidak jauh berbeda. Hal ini sesuai dengan hasil citra pada Gambar 4.1. (d), dimana terlihat hampir tidak ada perbedaan warna antara citra alluvial dan red soil. Dan terakhir adalah penggunaan latent space dimension dengan nilai 512. Score FID tertinggi dimulai dari alluvial soil, black soil, clay soil dan red soil. Pada Gambar 4.1 (e), citra sintesis yang tampak blur dan kombinasi warna yang kurang bagus terlihat pada citra sintesis kategori black soil, alluvial soil dan red soil.

Berikut adalah Gambar 5 Grafik score FID hasil citra sintesis untuk setiap kategori tanah menggunakan latent space dimension yang berbeda-beda.



Gambar 5 Grafik Score FID setiap kategori gambar

Berdasarkan gambar grafik diatas, disimpulkan bahwa untuk citra kategori alluvial memiliki kualitas citra terbaik saat menggunakan latent space dimension bernilai 100 dan yang paling buruk menggunakan nilai latent space dimension bernilai 512. Selanjutnya untuk kategori clay soil, kualitas citra terbaik dihasilkan saat menggunakan latent

space dimension 100 dan 512, sedangkan kualitas yang kurang bagus menggunakan latent space dimension 256. Pada kategori black soil, nilai latent space dimension yang menghasilkan kualitas citra bagus adalah 128 dan 256 sedangkan kualitas buruk menggunakan nilai 64. Terakhir pada kategori red soil, latent space dimension yang menghasilkan kualitas citra bagus yaitu 512 dan kualitas citra yang buruk dihasilkan menggunakan nilai 128.

Pada percobaan kedua, peneliti mencoba melakukan perhitungan score FID dengan menggabungkan setiap kategori gambar pada latent space dimension yang sama. Berikut adalah Tabel 4.3 hasil score FID pada percobaan kedua.

Tabel 4. 1 Hasil Score FID per Dataset

Kategori	Latent space dimensi (n)				
	64	100	128	256	512
Data_DCGAN	287,61	267,39	310,96	290,58	275,76

Jika melihat tabel diatas, penggunaan nilai latent space dimension yang dapat menghasilkan kualitas citra bagus dimulai dari 100, 512, 64, 256 dan terakhir adalah 128. Namun, apabila dilihat pada Gambar 4 (a), (b), (c), (d) dan (e), menurut pengamatan penelitian, citra sintesis yang memiliki kualitas bagus adalah dengan menggunakan latent space dimension 128. Pada citra sintesis hasil penggunaan latent space dimension 128, tidak banyak terlihat pixel pada gambar yang blur. Hanya saja, penilaian dengan cara melihat langsung adalah penilaian yang bersifat relative, artinya boleh jadi, masing-masing peneliti dapat memiliki perbedaan pendapat dalam penentuan citra yang memiliki kualitas bagus.

## V. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan oleh peneliti, dapat disimpulkan bahwa ada pengaruh latent space dimension terhadap kualitas hasil citra tanah yang dihasilkan oleh model DCGAN. Apabila dilihat secara langsung, tidak begitu nampak perbedaannya, namun apabila dievaluasi dengan menggunakan metrik score FID, dapat terlihat perbedaan score FID yang dihasilkan. Untuk kualitas citra terbaik pada kategori alluvial soil menggunakan latent space dimension 100. Untuk kategori clay soil, kualitas citra terbaik dihasilkan menggunakan latent space dimension 100 dan 512. Pada kategori black soil, penggunaan latent space dimension terbaik adalah 128 dan untuk red soil kualitas citra terbaik dihasilkan dengan

penggunaan latent space 512. Selain itu, apabila citra pada setiap kategori digabungkan pada latent space dimension yang sama diperoleh nilai FID score terbaik yaitu 276,39 dengan menggunakan latent space dimension bernilai 100. Dari hasil tersebut dapat membantu penelitian lain dalam memilih latent space dimension yang akan digunakan pada model DCGAN. Perlu adanya penelitian lebih lanjut atau pengembangan penelitian terkait penjelasan lebih detail terkait cara penilaian kualitas citra menggunakan FID score. Selain itu, perlu adanya pengembangan penelitian terkait arsitektur model DCGAN serta parameter-parameter yang berpengaruh terhadap kualitas citra yang dihasilkan oleh model DCGAN sehingga dapat dilakukan perbandingan score FID yang dihasilkan

#### UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada dosen pembimbing dan penguji Program Studi Teknologi Informasi Pasca Sarjana Universitas Amikom Yogyakarta, keluarga, teman-teman dan peneliti sendiri, yang selalu memberikan motivasi dan dukungan selama penelitian berlangsung.

#### DAFTAR PUSTAKA

- [1] M. G. Lanjewar and O. L. Gurav, "Convolutional Neural Networks based classifications of soil images," *Multimed. Tools Appl.*, vol. 81, no. 7, pp. 10313–10336, 2022, doi: 10.1007/s11042-022-12200-y.
- [2] R. Thakur, "Recent Trends Of Machine Learning In Soil Classification : A Review," no. November, pp. 25–32, 2018.
- [3] U. Barman and R. D. Choudhury, "Soil texture classification using multi class support vector machine," *Inf. Process. Agric.*, vol. 7, no. 2, pp. 318–332, 2020, doi: 10.1016/j.inpa.2019.08.001.
- [4] B. Bhattacharya and D. P. Solomatine, "Machine learning in soil classification," *Neural Networks*, vol. 19, no. 2, pp. 186–195, 2006, doi: 10.1016/j.neunet.2006.01.005.
- [5] X. Ying, "An Overview of Overfitting and its Solutions," *J. Phys. Conf. Ser.*, vol. 1168, no. 2, 2019, doi: 10.1088/1742-6596/1168/2/022022.
- [6] I. Marin, S. Gotovac, M. Russo, and D. Božić-Štulić, "The effect of latent space dimension on the quality of synthesized human face images," *J. Commun. Softw. Syst.*, vol. 17, no. 2, pp. 124–133, 2021, doi: 10.24138/jcomss-2021-0035.
- [7] A. Radford, L. Metz, and S. Chintala, "Unsupervised representation learning with deep convolutional generative adversarial networks," *4th Int. Conf. Learn. Represent. ICLR 2016 - Conf. Track Proc.*, pp. 1–16, 2016.
- [8] K. M. N. and M. Hwang, "Finding the best k for the dimension of the latent space in autoencoders," in *International Conference on Computational Collective Intelligence*, 2020, pp. 453–464. doi: 10.1007/978-3-030-63007-2\_35.
- [9] M. Of, T. H. E. Latent, S. On, T. O. Fit, T. H. E. Distribution, and T. H. E. A. Of, "Impact of the latent space on the ability of GANs to fit the distribution," no. 2014, pp. 1–13, 2020.
- [10] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, and S. Hochreiter, "GANs trained by a two time-scale update rule converge to a local Nash equilibrium," *Adv. Neural Inf. Process. Syst.*, vol. 2017-Decem, no. Nips, pp. 6627–6638, 2017.
- [11] E. Secada Purba, "IMPLEMENTATION OF GENERATIVE ADVERSARIAL NETWORKS FOR CREATING DIGITAL ARTWORK IN THE FORM OF ABSTRACT IMAGES."
- [12] B. Liu, J. Lv, X. Fan, J. Luo, and T. Zou, "Application of an Improved DCGAN for Image Generation," *Mob. Inf. Syst.*, vol. 2022, 2022, doi: 10.1155/2022/9005552.
- [13] A. Borji, "Pros and cons of GAN evaluation measures," *Comput. Vis. Image Underst.*, vol. 179, pp. 41–65, 2019, doi: 10.1016/j.cviu.2018.10.009.
- [14] S. K. Venu and S. Ravula, "Evaluation of deep convolutional generative adversarial networks for data augmentation of chest x-ray images," *Futur. Internet*, vol. 13, no. 1, pp. 1–13, 2021, doi: 10.3390/fi13010008.
- [15] "pytorch-fid," 2023. <https://pypi.org/project/pytorch-fid/>