

**TESIS**

**KLASIFIKASI JENIS TANAH MENGGUNAKAN  
DEEP CONVOLUTIONAL GENERATIVE ADVERSIAL DAN  
CONVOLUTIONAL NEURAL NETWORK**



Disusun oleh:

**Nama : Patmawati**  
**NIM : 21.55.1024**  
**Konsentrasi : Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2023**

**TESIS**

**KLASIFIKASI JENIS TANAH MENGGUNAKAN  
DEEP CONVOLUTIONAL GENERATIVE ADVERSIAL DAN  
CONVOLUTIONAL NEURAL NETWORK**

**SOIL TYPE CLASSIFICATION USING DEEP CONVOLUTIONAL  
GENERATIVE ADVERSIAL AND CONVOLUTIONAL NEURAL  
NETWORK**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

**Nama : Patmawati**

**NIM : 21.55.1024**

**Konsentrasi : Business Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2023**

**HALAMAN PENGESAHAN**

**KLASIFIKASI JENIS TANAH MENGGUNAKAN  
DEEP CONVOLUTIONAL GENERATIVE ADVERSIAL DAN  
CONVOLUTIONAL NEURAL NETWORK**

**SOIL TYPE CLASSIFICATION USING DEEP CONVOLUTIONAL  
GENERATIVE ADVERSIAL AND CONVOLUTIONAL NEURAL  
NETWORK**

Dipreparasi dan Disusun oleh

**Patmawati**

**21.55.1024**

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Senin, tanggal 04 Desember 2023

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 04 Desember 2023

**Rektor**

**Prof. Dr. M. Suyanto, M.M.**  
**NIK. 190302001**

**HALAMAN PERSETUJUAN**

**KLASIFIKASI JENIS TANAH MENGGUNAKAN  
DEEP CONVOLUTIONAL GENERATIVE ADVERSIAL DAN  
CONVOLUTIONAL NEURAL NETWORK**

**SOIL TYPE CLASSIFICATION USING DEEP CONVOLUTIONAL  
GENERATIVE ADVERSIAL AND CONVOLUTIONAL NEURAL  
NETWORK**

Dipersiapkan dan Disusun oleh

**Patmawati**

**21.55.1024**

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Senin, tanggal 04 Desember 2023

**Pembimbing Utama**

**Dr. Andi Sunyoto, M. Kom**

**NIK. 190302052**

**Anggota Tim Penguji**

**Prof. Dr. Ema Utami, S.Si, M.Kom**

**NIK. 190302037**

**Pembimbing Pendamping**

**Emha Taufiq Luthfi, S.T., M.Kom.**

**NIK. 190302125**

**Dr. Ferry Wahyu Wibowo, S.Si, M.CS**

**NIK. 190302235**

**Dr. Andi Sunyoto, M. Kom**

**NIK. 190302052**

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 04 Desember 2023

**Direktur Program Pascasarjana**

**Prof. Dr. Kusriani, M.Kom.**

**NIK. 190302106**

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Patmawati  
NIM : 21.55.1024  
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:

**KLASIFIKASI JENIS TANAH MENGGUNAKAN DEEP  
CONVOLUTIONAL GENERATIVE ADVERSIAL DAN  
CONVOLUTIONAL NEURAL NETWORK**

Dosen Pembimbing Utama : Dr. Andi Sunyoto, M. Kom  
Dosen Pembimbing Pendamping : Emha Taufiq Luthfi, S.T., M. Kom

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 04 Desember 2023

Yang Menyatakan,

  
Patmawati

## HALAMAN PERSEMBAHAN

Bapak dan Mama, saudara-saudaraku serta teman-temanku yang tidak dapat kusebut satu persatu. Semoga ridho, do'a, semangat, serta dukungan yang kalian berikan dapat menghantarkanku meraih gelar Magister ini. Ilmu yang aku peroleh semoga kelak akan menjadi berkah, amal ibadah, pahala, dan bermanfaat untuk keluargaku serta orang-orang disekitarku. Semoga apa yang kupersembahkan ini dapat membuat kalian bangga atas semangat, doa dan dukungan yang telah kalian berikan.



## HALAMAN MOTTO

Hidup pada dasarnya tidak menjamin apa-apa. Hanya berusaha semaksimal mungkin membangun harapan lewat Pendidikan. Ini tentang pilihan, tidak perlu dibanding-bandingkan. Nikmati prosesnya maka hasil tidak akan mengkhianatinya. Niat baik, pasti akan dipermudahkannya oleh-Nya



## KATA PENGANTAR

Puji syukur kehadiran Allah Swt, Tuhan Yang Maha Esa, atas segala Rahmat dan karunia-NYA sehingga penulis dapat menyelesaikan Tesis yang berjudul

### **KLASIFIKASI JENIS TANAH MENGGUNAKAN DEEP CONVOLUTIONAL GENERATIVE ADVERSIAL DAN CONVOLUTIONAL NEURAL NETWORK.**

Laporan Tesis ini disusun untuk memenuhi salah satu syarat akademis dalam menyelesaikan Program Studi S2 Teknik Informatika Program Pascasarjana Universitas AMIKOM Yogyakarta.

Pada kesempatan ini, penulis ingin mengucapkan terima kasih kepada :

1. Allah SWT, yang telah memberikan segalanya sehingga laporan Tesis ini dapat terselesaikan dengan baik.
2. Kedua orang tuaku dan saudara-saudaraku, kakak dan adikku atas semua dukungan dan do'anya
3. Dr. Andi Sunyoto, M. Kom., Dosen pembimbing dan juga inspirator saya, yang memberikan pengetahuan, semangat dan dukungan dalam menyelesaikan laporan tesis ini. Semoga bapak, sehat selalu.
4. Bapak Emha Taufiq Luthfi, S.T., M.Kom. Dosen pembimbing saya, yang juga selalu mendukung laporan penulisan tesis saya.
5. Kepada Bapak dan Ibu selaku Penguji saya, yang membantu memberikan masukan serta menerima kekurangan dari penulisan tesis ini
6. Semua teman-teman yang telah memberikan dukungan dan semangat




kepada saya untuk menyelesaikan program studi ini.

Menyadari bahwa dalam laporan Tesis ini masih terdapat banyak sekali kekurangan, penulis sangat mengharapkan saran dan kritik yang membangun dari semua pihak yang akan sangat berguna untuk perbaikan dan penyempurnaan laporan Tesis ini.

Yogyakarta, 04 Desember 2023

Penulis



## DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xiv
INTISARI.....	xv
<i>ABSTRACT</i> .....	xvi
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	5
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian.....	5
1.5. Manfaat Penelitian.....	6
BAB II TINJAUAN PUSTAKA.....	7
2.1. Tinjauan Pustaka.....	7
2.2. Keaslian Penelitian.....	11

2.3. Landasan Teori.....	14
2.3.1. Klasifikasi.....	14
2.3.2. Tanah.....	14
2.3.3. GAN (Generative Adversarial Network).....	15
2.3.4. DCGAN (Deep Convolutional Generative Adversarial Network).....	16
2.3.5. Fungsi Objektif GAN.....	17
2.3.6. Loss Function GAN.....	18
2.3.7. Latent Space Dimension.....	19
2.3.8. Resnet152V2 model.....	19
2.3.9. VGG-16 and VGG-19 model.....	20
2.3.10. Xception Model.....	20
2.3.11. Inception ResNetV2 model.....	21
2.3.12. DenseNet201 model.....	22
2.3.13. Fréchet Distance of Inception (FID).....	23
2.3.14. Evaluasi Performance Klasifikasi Citra.....	24
<b>BAB III METODE PENELITIAN.....</b>	<b>26</b>
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	26
3.2. Metode Pengumpulan Data.....	26
3.3. Metode Augmentasi Data.....	28
3.4. Metode Analisis Data.....	29
3.5. Alur Penelitian.....	30

BAB IV HASIL PENELITIAN DAN PEMBAHASAN .....	34
4.1. Augmentasi Data .....	34
4.2. Evaluasi Data Sintesis .....	36
4.3. Evaluasi Performa Klasifikasi CNN .....	43
4.2.1. Hasil Evaluasi pada Arsitektur ResNet152V2 .....	44
4.2.2. Hasil Evaluasi pada Arsitektur VGG16 .....	48
4.2.3. Hasil Evaluasi pada Arsitektur VGG19 .....	51
4.2.4. Hasil Evaluasi pada Arsitektur DenseNet201 .....	55
4.2.5. Hasil Evaluasi pada Arsitektur InceptionResNetV2 .....	59
4.2.6. Hasil Evaluasi pada arsitektur Xception .....	63
4.2.7. Hasil Evaluasi pada arsitektur CNN .....	67
4.2.8. Perbandingan dan penelitian sebelumnya .....	72
BAB V PENUTUP .....	77
5.1. Kesimpulan .....	77
5.2. Saran .....	78
DAFTAR PUSTAKA .....	79

## DAFTAR TABEL

Tabel 2. 1 Matriks literatur review dan posisi penelitian.....	11
Tabel 2. 2 Variabel Fungsi Objektif GAN.....	17
Tabel 2. 3 Metrics Confusion.....	24
Tabel 3. 1 Jumlah Dataset.....	26
Tabel 4. 1 Jumlah Data Hasil Augmentation.....	36
Tabel 4. 2 Hasil Score FID Per Kategori.....	40
Tabel 4. 3 Hasil Score FID per Dataset.....	42
Tabel 4. 4 Pembagian Daaset.....	43
Tabel 4. 5 Performance Metrics Arsitektur ResNet152V2.....	44
Tabel 4. 6 Performance Metrics Arsitektur VGG16.....	48
Tabel 4. 7 Performance Metrics Arsitektur VGG19.....	51
Tabel 4. 8 Performance Metrics Arsitektur DenseNet201.....	55
Tabel 4. 9 Performance Metrics Arsitektur InceptionResNetV2.....	59
Tabel 4. 10 Performance Metrics Arsitektur Xception.....	63
Tabel 4. 11 Performance Metrics Arsitektur CNN.....	68
Tabel 4. 12 Perbandingan Akurasi Terhadap Dataset.....	75
Tabel 4. 13 Perbandingan Akurasi dengan Penelitian Sebelumnya.....	75

## DAFTAR GAMBAR

Gambar 2. 1 Arsitektur GAN.....	15
Gambar 2. 2 Arsitektur DCGAN.....	17
Gambar 2. 3 Arsitektur VGG16 dan VGG19 .....	20
Gambar 2. 4 Arsitektur Exception Model .....	21
Gambar 2. 5 Arsitektur Inception Resnet V2.....	22
Gambar 2. 6 Arsitektur DenseNet201.....	22
Gambar 4. 1 Hasil Augmentasi dengan variasi latent space dimension $\dim(z) \in \{64, 100, 128, 256, 512\}$ .....	37
Gambar 4. 2 Grafik Score FID setiap kategori gambar .....	41
Gambar 4. 3 Confusion Metrics Arsitektur ResNet152V2 .....	47
Gambar 4. 4 Confusion Metrics Arsitektur VGG16 .....	50
Gambar 4. 5 Confusion Metrics Arsitektur VGG19 .....	54
Gambar 4. 6 Confusion Metrics Arsitektur DenseNet201 .....	58
Gambar 4. 7 Confusion Metrics Arsitektur InceptionResNetV2 .....	62
Gambar 4. 8 Confusion Metrics Arsitektur Xception .....	66
Gambar 4. 9 Arsitektur CNN yang diajukan.....	67
Gambar 4. 10 Confusion Metrics Arsitektur CNN .....	70
Gambar 4. 11 Grafik akurasi pada setia Arsitektur.....	71
Gambar 4. 12 Grafik Perbandingan Akurasi dengan Penelitian Sebelumnya .....	73

## INTISARI

Penelitian terkait klasifikasi jenis tanah telah dibanyak dilakukan oleh para peneliti. Masing-masing penelitian tersebut menggunakan metode klasifikasi serta dataset yang berbeda. Terdapat ketidakseimbangan jumlah data pada setiap kategori dataset oleh beberapa penelitian. Ketidakseimbangan dataset tersebut tentunya dapat menghasilkan performa model yang buruk atau over fit, khususnya pada metode deep learning. Untuk menangani masalah tersebut dapat dilakukan melalui proses augmentasi data sintesis dengan menggunakan model DCGAN. Dimana, jaringan generator pada model DCGAN memiliki layer inputan awal laten space dimension  $dim(z)$  yang nilainya dapat bervariasi, yaitu 64,100, 128, 256 dan 512. Ukuran latent space dimension sangat penting dalam melakukan rekonstruksi data atau citra saat proses pelatihan data.

Penelitian ini, melakukan uji coba augmentasi citra sintesis terhadap kategori yang mengalami imbalance pada dataset kemudian melakukan klasifikasi menggunakan model DCCN untuk mengetahui akurasi yang dihasilkan dari proses klasifikasi dengan menggunakan citra sintesis. Model CCN yang digunakan yaitu *ResNet152V2*, *VGG-16*, *VGG-19*, *Inception-ResNetV2*, *Exception*, *DenseNet201* dan CNN. Selanjutnya, untuk menguji efek dimensi ruang laten pada citra yang dihasilkan menggunakan metode evaluasi secara kuantitatif, yaitu *Frechet Inception Distance* (FID). Dan untuk mengukur performance model dalam melakukan klasifikasi digunakan *confusion matrices*. Score terkecil dari FID menunjukkan model GAN yang lebih baik dalam menghasilkan citra sintesis. Hasil evaluasi didapatkan score terkecil bernilai 267,39 dengan menggunakan inputan latent space dimension yang ber nilai 100. Kemudian, hasil confusion metrics terbaik didapatkan dengan menggunakan model CNN dimana nilai akurasi, precision dan F1-Score yang didapatkan sebesar 99%

Kata kunci: Augmentasi Data, DCGAN, latent space dimension, DCCN, *Frechet Inception Distance*

## ABSTRACT

Research related to soil type classification has been conducted by many researchers. Each of these studies uses different classification methods and datasets. There is an imbalance in the amount of data in each dataset category by several studies. This dataset imbalance can certainly result in poor model performance or over fit, especially in deep learning methods. To handle this problem, it can be done through the synthesis data augmentation process using the DCGAN model. Where, the generator network in the DCGAN model has an initial input layer latent space dimension whose value can vary, namely 64, 100, 128, 256 and 512. The size of the latent space dimension is very important in reconstructing data or images during the data training process.

In this study, we tested synthetic image augmentation for categories that experienced imbalance in the dataset and then performed classification using the CCN model to determine the accuracy resulting from the calcification process using synthetic images. The DCCN models used are RestNet152V2, VGG-16, VGG-19, Inception-RestNetV2, Exception, DenseNet201 and CNN. Furthermore, to test the effect of latent space dimensions on the resulting image using a quantitative evaluation method, namely Fre'chet Inception Distance (FID). And to measure the performance of the model in classification, confusion metrics are used. The smallest FID score indicates a better GAN model in generating synthesized images. The evaluation results obtained the smallest score is 267.39 by using latent space dimension input which has a value of 100. Then, the best confusion metrics results were obtained using the CNN model where the accuracy, precision and F1-Score values obtained were 99%.

*Keywords: Data Augmentation, DCGAN, latent space dimension, DCCN, Fre'chet Inception Distance*



# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Sebagai negara agraris yang memiliki lahan pertanian dan perkebunan yang luas maka penting bagi para petani ataupun para pekebun Indonesia untuk memahami sistem pengolahan lahan, termasuk diantaranya pemahaman tentang jenis tanah. Sebuah lahan dapat atau tidak dapat digunakan tergantung kepada kualitas jenis tanah yang ada di lahan tersebut (Robbani et al. 2016). Pemanfaatan dari *Artificial Intelligence* serta *Machine Learning* dalam image processing dapat membantu dalam mendeteksi atau mengklasifikasi jenis tanah (Lanjewar and Gurav 2022).

Beberapa penelitian terkait klasifikasi jenis tanah menggunakan machine learning telah dilakukan. Chandan et al. (Thakur 2018) telah melakukan review terkait teknik machine learning yang digunakan dalam mengklasifikasi jenis tanah, diantaranya Decision Tree, K-Nearest Network (KNN), Support Vector Machine (SVM) dan ANN. Choudhury et al. (Barman and Choudhury 2020) melakukan penelitian untuk menangani multi class dalam klasifikasi jenis tanah dengan menggunakan metode SVM. Bhattacharya et al. (Bhattacharya and Solomatine 2006) melakukan klasifikasi jenis tanah menggunakan DT, ANN dan SVM berdasarkan segmentation warna tanah. Masing-masing penelitian tersebut menggunakan dataset yang berbeda dengan model pengambilan data yang juga berbeda, sehingga tidak dapat melakukan perbandingan model. Selain itu, dalam

melakukan klasifikasi citra menggunakan machine learning dengan *high-dimensional data*, dapat menghasilkan proses feature extraction menjadi buruk (Wickramasinghe, Marino, and Manic 2021). Dibutuhkan proses feature extraction terhadap informasi-informasi yang penting dalam citra, sehingga sangat penting untuk mengambil citra pada bagian-bagian yang relevan dengan informasi yang dicari (Pintelas, E.; Livieris, I.E.; Pintelas 2021).

*Deep Convolutional Neural Network (DCNN)* adalah pengembangan model CNN yang sangat membantu dalam mengatasi masalah *Machine Learning* atau *Computer Vision*. Model CNN merupakan bagian *Deep Learning* yang dapat melakukan metode extraction citra secara otomatis (Prilianti et al. 2020) dan banyak diaplikasikan untuk klasifikasi citra dikarenakan kemampuannya dalam mempelajari inputan data secara otomatis (Ayan, Erbay, and Varçın 2020). Seperti penelitian Lanjewar et al. (Lanjewar and Gurav 2022) yang melakukan klasifikasi citra tanah menggunakan enam model DCNN, yaitu RestNet152V2, VGG-16, VGG-19, Inception-ResNetV2, Exception dan DenseNet201. Performa akurasi dari model yang dihasilkan rata-rata mencapai 98.46%. Deep Learning merupakan metode yang sangat berguna dalam melakukan klasifikasi tanah berdasarkan jenis dan karakternya dengan menggunakan citra (Lanjewar and Gurav 2022) serta dapat memberikan hasil akurasi tertinggi (Silva et al. 2019).

Namun, dalam menggunakan teknik *Deep Learning* untuk melakukan tugas *image recognition* atau *image classification* membutuhkan volume dataset yang sangat besar untuk proses training model (Venu and Ravula 2021). Saat ini, banyak dataset yang bersifat *non-public* atau tidak dapat diakses. Terbatasnya

dataset tersebut dapat mengakibatkan jumlah dataset yang sedikit, serta terjadi ketidakseimbangan jumlah data pada setiap kelasnya yang akan menghasilkan performa model *Deep learning* menjadi buruk atau overfitting (Ying 2019). Dengan augmentation data, variasi data baru dapat terbentuk.

Salah 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 innovative yaitu *Generative Adversial Network (GAN)* (Waheed et al. 2020). Citra sintesis yang dibentuk dengan model generative memungkinkan lebih banyak variasi serta memperbanyak dataset yang dapat meningkatkan proses training (Frid-Adar et al. 2018). GAN telah diimplementasi di beberapa penelitian untuk menghasilkan citra sintesis berkualitas tinggi yang digunakan dalam 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)* yang memanfaatkan teknik *Convolutional Neural Network (CNN)* untuk menampilkan informasi representative yang baru dari hasil perkalian pada bagian citra terhadap filter yang digunakan (Radford, Metz, and Chintala 2016). *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. (Marin et al. 2021). Transformasi gambar yang bermakna dihasilkan dari latent vector melalui operasi aritmatika dalam latent space dimension (Radford, Metz, and Chintala 2016). Penelitian sebelumnya (Hwang 2020), 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 (Of et al. 2020).

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 (Marin et al. 2021). Terdapat dua metrik evaluasi GAN secara kuantitatif, salah satunya adalah Frechet Inception Distance (FID). Metrik tersebut melakukan perhitungan terhadap kemiripan gambar yang dihasilkan dan gambar asli dari data training (Heusel et al. 2017).

Berdasarkan penjelasan diatas, maka pada penelitian ini, peneliti mencoba melakukan riset pembuatan citra sintesis menggunakan model DCGAN dengan percobaan perubahan nilai parameter pada latent space dimension untuk mengetahui pengaruhnya terhadap kualitas gambar yang dihasilkan. Hasil citra sintesis tersebut kemudian digunakan pada proses klasifikasi menggunakan metode pengembangan arsitektur CNN (*Convolution Neural Network*) untuk mengetahui performa klasifikasi dari model pengembangan arsitektur CNN tersebut terhadap penggunaan gambar sintesis. Diharapkan dengan adanya penelitian ini, dapat membantu dalam pembuatan dataset citra untuk menangani

masalah ketersediaan dataset yang kurang serta untuk mengetahui penggunaan data citra sintesis terhadap proses klasifikasi menggunakan metode deep learning.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang diatas, maka perumusan masalah yang ada pada penelitian yang dilakukan oleh penulis yaitu.

- a. Berapakah nilai parameter latent dimensi (*latent dimension*) yang digunakan pada model DCGAN, untuk menghasilkan citra yang berkualitas?
- b. Apakah augmentasi data menggunakan metode *Deep Convolutional Generative Network* (DCGAN) dapat meningkatkan akurasi klasifikasi tanah?

## 1.3. Batasan Masalah

Adapun batasan masalah dalam penelitian ini yaitu:

- a. Dataset citra yang digunakan adalah Citra tanah terdiri atas empat kategori tanah, yaitu *Alluvial\_Soil*, *Black\_Soil*, *Clay\_Soil* dan *Red\_Soil*. Dataset telah digunakan dalam penelitian sebelumnya (Lanjewar and Gurav 2022)
- b. Metode klasifikasi yang digunakan menggunakan model pengembangan CNN Convolutional Neural Network (CNN) yang terdiri atas arsitektur, ResNet152V2, VGG16, VGG19, Xception, Inception ResNetV2, DenseNet201, CNN.

## 1.4. Tujuan Penelitian

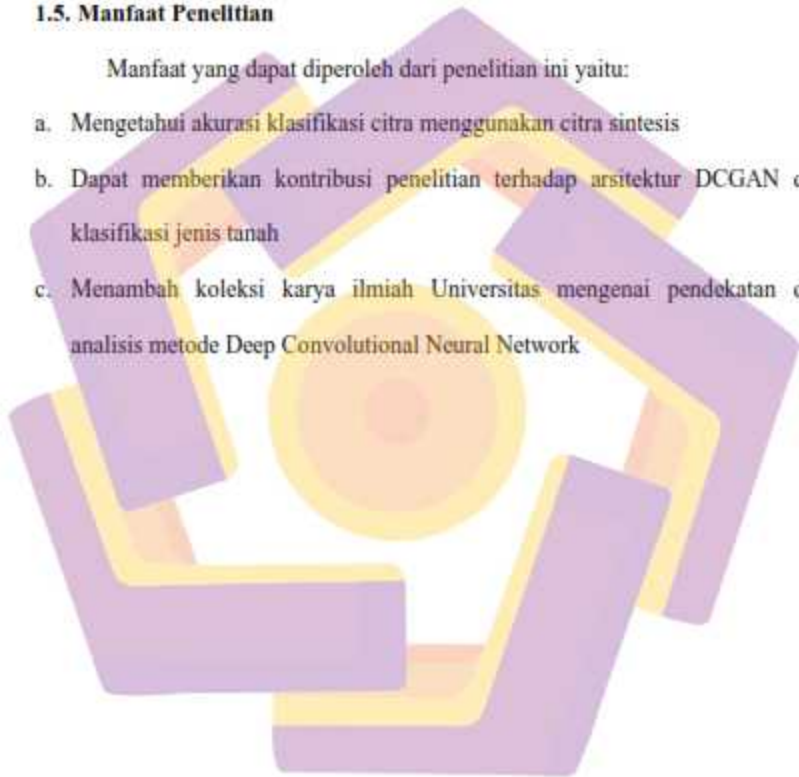
Tujuan dari pelaksanaan penelitian ini sebagai berikut:

- a. Memilih nilai parameter latent dimensi (*latent space dimension*) terbaik pada model DCGAN untuk menghasilkan gambar yang berkualitas
- b. Memilih metode klasifikasi yang baik untuk peninsrgkatan hasil akurasi

### 1.5. Manfaat Penelitian

Manfaat yang dapat diperoleh dari penelitian ini yaitu:

- a. Mengetahui akurasi klasifikasi citra menggunakan citra sintesis
- b. Dapat memberikan kontribusi penelitian terhadap arsitektur DCGAN dan klasifikasi jenis tanah
- c. Menambah koleksi karya ilmiah Universitas mengenai pendekatan dan analisis metode Deep Convolutional Neural Network



## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Tinjauan Pustaka

Berikut adalah beberapa penelitian yang dijadikan rujukan dalam penelitian yang akan dilakukan, diantaranya yaitu Penelitian klasifikasi citra tanah menggunakan DCNN (Lanjewar and Gurav 2022). Penelitian ini dilakukan untuk menghasilkan algoritma Deep Learning yang terbaik dan cepat dalam melakukan klasifikasi citra tanah. Penelitian ini mencoba melakukan klasifikasi citra tanah menggunakan lima arsitektur DCNN, yaitu *snet152V2*, VGG-16, VGG-19, Inception-ResNetV2, Xception, and DenseNet201 dengan jumlah data sebanyak 903. Dataset yang digunakan terdiri atas empat kategori yaitu Alluvial Soil, Black Soil, Clay Soil dan Red Soil. Adanya proses augmentasi tradisional yaitu *Rotation-range*, *Zooming range*, *Width-shifting range*, *Height (vertical) shifting range*, *Shear angle range*, *Horizontal flipping*, *Vertical flipping*, *Fill-mode* sebelum training proses. Optimizer yang di uji menggunakan Adam dan RMSprop dengan epoch 200. Hasil Akurasi klasifikasi citra terbaik mencapai 99.86% untuk proses training, dan 97.68% untuk proses validation dengan menggunakan model CNN yang dibangun sendiri. Evaluasi untuk model klasifikasi menggunakan teknik K-fold dan Confusion Matrix.

Pada 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 fit 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 dim 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 mengguna 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. Skenarion 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. Dataset yang baru dibuat Dataset baru yang berhasil dibuat kemudian di split untuk proses klasifikasi citra menggunakan model CNN. Pembagian dataset yaitu 80% untuk training, 10%



validasi dan 10% testing. Arsitektur CNN yang digunakan untuk klasifikasi citra terdiri atas AlexNet, DenseNet, ResNet, dan Xception. Dari 4 model CNN yang digunakan, nilai akurasi tertinggi didapatkan dari arsitektur DenseNet sebesar 88,86% dengan menggunakan proses augmentasi data yaitu DCGAN model yang di training sebanyak 1000 epoch.

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. Penjelasan dan pemaparan dalam penelitian tidak dijelaskan lebih detail. Dengan menggunakan model GMD didapatkan akurasi klasifikasi menjadi meningkat ketika ditambahkan proses augmentasi DCGAN. Dari 76,58% menjadi 80,45% untuk data pelatihan dan 76,42% menjadi 83,74% untuk validasi.

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 yang mencapai nilai 91.7%.

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. Didapatkan performa klasifikasi citra hati lesion meningkat dari 78.6% sensitivity dan 88.4% specificity menjadi 85.7% sensitivity, dan 92.4 specificity dengan model DCGAN. Perlu ditambahkan penyajian table confusion matrix untuk mengetahui seberapa banyak citra yang dapat diklasifikasikan dengan benar, mengingat jumlah dataset yang digunakan masih tergolong sedikit, yang dapat berakibat pada model yang overfit.

## 2.2.Keaslian Penelitian

Tabel 2. 1 Matriks literatur review dan posisi penelitian

### KLASIFIKASI JENIS TANAH MENGGUNAKAN DEEP CONVOLUTIONAL GENERATIVE ADVERSIAL DAN CONVOLUTIONAL NEURAL NETWORK

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Convolutional Neural Networks based classifications of soil images	Lanjewar, M G, Gurav, O L, Multimedia Tools and Applications, 2022, ISSN 1573-7721 (Belum terindeks tahun 2022)	Menghasilkan algoritma Deep Learning yang terbaik untuk klasifikasi citra tanah	Algoritma CNN yang diusulkan lebih baik, menghasilkan Accuracy mencapai 99,86%	<ul style="list-style-type: none"> <li>• Imbalance dataset Hasil CNN lebih tinggi dibandingkan hasil DCNN</li> </ul>	<ul style="list-style-type: none"> <li>• penggunaan augmentasi dengan model DCGAN untuk mengatasi imbalance terhadap dataset.</li> </ul>
2	Evaluation of deep convolutional generative adversarial networks for data augmentation of chest x-ray images	Venu, Sagar Kora Ravula, Sridhar, Future Internet, 2021. Q2	Menghasilkan dataset citra sinar-X dada	<ul style="list-style-type: none"> <li>• Augmentasi data menggunakan DCGAN berhasil membuat citra yang mirip dengan data asli</li> <li>• Evaluasi Model menggunakan Fréchet Distance of Inception (FID) dengan score 1.289</li> </ul>	<ul style="list-style-type: none"> <li>• Tidak ada penjelasan terkait jumlah data sintesis yang dihasilkan.</li> <li>• Perlu dilakukan klasifikasi menggunakan DL menggunakan data hasil sintesis untuk mengetahui akurasi yang dihasilkan.</li> </ul>	<ul style="list-style-type: none"> <li>• Objek penelitian yang berbeda</li> <li>• Penelitian yang diajukan menambahkan model DL untuk mengetahui hasil akurasi yang didapatkan berdasarkan data sintesis</li> <li>• Penelitian yang diajukan mencoba mengubah latent_dim yang digunakan</li> </ul>

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	Data Augmentation using Adversarial Networks for Tea Diseases Detection	Yuwana, R. Sandra Fauziah, Fani Heryana, Ana Krisnandi, Dikdik Kusumo, R. Budiarianto Suryo Pardede, Hilman F.  Jurnal Elektronika dan Telekomunikasi, 2020, Sinta2.	Membandingkan hasil augmentasi data model DCGAN dan GAN terhadap DCNN	Akurasi klasifikasi penyakit daun tea terbaik menggunakan arsitektur DenseNet dengan nilai mencapai 88,86% menggunakan augmentasi model DCGAN	<ul style="list-style-type: none"> <li>Penambahan data tanpa memperhatikan balance data pada tiap-tiap kategori penyakit daun tea</li> <li>Pengujian model klasifikasi data tidak dipaparkan dalam penulisan.</li> </ul> Perlu tambahkan model pengujian accuracy dari model klasifikasi yang digunakan	<ul style="list-style-type: none"> <li>Penelitian yang diusulkan hanya menggunakan augmentasi model DCGAN</li> <li>Model klasifikasi yang digunakan untuk penelitian yang diusulkan adalah ResNet152V2, VGG16, VGG19, Inception ResNetV2, Xception dan DenseNet</li> <li>Pengujian model DCGAN menggunakan FID</li> <li>Pengujian model DCNN menggunakan confusion matrix.</li> </ul>
4	DCGAN for enhancing eye diseases classification	Smaida, Mahmoud Yaroshchak, Serhii El Barg, Youness,  CEUR Workshop Proceedings, 2021	Meningkatkan akurasi klasifikasi citra penyakit mata menggunakan augmentasi DCGAN	Akurasi klasifikasi menggunakan GMD model meningkat dari 76,58% menjadi 80,45% untuk training dan 76,42% menjadi 83,74% untuk validation	<ul style="list-style-type: none"> <li>Data yang digunakan setelah augmentasi menjadi tidak balance.</li> <li>Pengukuran performa training, evaluate dan validation menggunakan GMD model</li> <li>Penjelasan model GMD tidak dijabarkan dengan jelas</li> </ul>	<ul style="list-style-type: none"> <li>Penelitian yang diusulkan hanya menggunakan augmentasi model DCGAN untuk membalance dataset.</li> <li>Adanya evaluasi data menggunakan confusion matrix</li> <li>Model klasifikasi yang digunakan untuk penelitian yang diusulkan adalah ResNet152V2, VGG16</li> </ul>

Tabel 2.1. (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
					<ul style="list-style-type: none"> <li>Pembagian dataset adalah 70% training, 15% validation, dan 15% evaluation.</li> </ul>	VGG19, Inception ResNetV2, Xception dan DenseNet <ul style="list-style-type: none"> <li>Pengujian model DCGAN menggunakan FID</li> </ul>
5	Combining DC-GAN with ResNet for blood cell image classification	Ma, Li Shuai, Renjun Ran, Xuming Liu, Wenjun Ye, Chao.  Medical and Biological Engineering and Computing, 2020 (Q2)	Menyelesaikan masalah unbalance data pada dataset sel darah dengan model DCGAN untuk klasifikasi citra	Performa klasifikasi menjadi meningkat menggunakan arsitektur Resnet dengan hasil nilai akurasi mencapai 91,7%	Data hasil augmentasi hanya ditambahkan untuk data training saja	<ul style="list-style-type: none"> <li>Penelitian yang diusulkan tidak menambahkan operasi matrix transformation (flipping, clipping dan scaling) dalam model DCGAN</li> </ul>

### 2.3. Landasan Teori

#### 2.3.1. Klasifikasi


Klasifikasi merupakan proses pengkelompokan atau pengkategorian berdasarkan pada ciri-ciri tertentu kedalam suatu kelompok. Klasifikasi citra atau yang disebut dengan *Image Classification* merupakan proses dalam menemukan definisi-definisi kesamaan karakteristik dalam suatu kelompok ataupun kelas (class). Klasifikasi citra mengacu kepada tugas penggalian kelas informasi dari suatu citra raster multiband (Diantoro and Adriansyah 2019). Tujuannya untuk memperkirakan kelas suatu objek yang belum terlabeli atau belum terkategori. Sehingga kita bisa dengan mudah mengetahui objek

#### 2.3.2. Tanah

Tanah adalah benda alami yang berada di permukaan bumi dan menjadi tempat ataupun media hidup bagi semua makhluk hidup. Tanah terbentuk akibat adanya proses pelapukan pada bebatuan. Tanah dapat didefinisikan sebagai salah satu komponen alami yang terdiri atas padatan yang dapat berupa mineral ataupun materi organik, cairan, serta gas yang membentuk sebuah permukaan dari lahan, ataupun daerah lapang (Robbani et al. 2016). Tanah untuk setiap daerah memiliki jenis yang berbeda-beda, tergantung dari iklim, vegetasi, jenis batuan pada daerah tersebut, serta pengaruh lingkungan sekitar. Berikut beberapa jenis tanah yang dapat ditemui di daerah asia, termasuk Indonesia, diantaranya yaitu Alluvial Soil (tanah aluvial), Black Soil (tanah hitam/humus), Peat Soil (tanah gambut) dan Red Soil (tanah merah).

### 2.3.3. GAN (Generative Adversarial Network)

GAN (*Generative Adversarial Network*) merupakan salah satu pendekatan pemodelan generative yang pertamakali diperkenalkan oleh Goodfellow et. al (Goodfellow et al. 2020). GAN adalah arsitektur jaringan saraf tiruan yang dapat membentuk atau membangkitkan suatu data menjadi data yang baru berdasarkan kumpulan data yang telah di lihat sebelumnya. Data utama yang digunakan oleh jaringan GAN adalah data citra. Arsitektur GAN dibentuk oleh dua jaringan yang berbeda, yaitu *Generator (G)* dan *Discriminator (D)*. Berikut adalah Gambar 2.1 Arsitektur GAN



Gambar 2. 1 Arsitektur GAN

Arsitektur Generator adalah jaringan yang menerima inputan sebuah vector angka  $z$  yang umumnya dibangkitkan secara acak, dan kemudian angka tersebut diubah menjadi sebuah output citra tiga dimensi. Tugas arsitektur generator adalah membuat suatu citra tiga dimensi yang palsu untuk menipu jaringan discriminator (Ma et al. 2020)


Arsitektur Discriminator merupakan jaringan yang melakukan klasifikasi biner terhadap output yang dihasilkan oleh arsitektur generator. Jadi, inputan dari jaringan discriminator adalah citra tiga dimensi yang dihasilkan oleh arsitektur generator. Klasifikasi biner yang dihasilkan menyatakan apakah inputan citra adalah citra asli dari dataset atau merupakan citra buatan dari arsitektur generator (fake). Arsitektur discriminator dilatih berdasarkan data citra yang dihasilkan oleh arsitektur generator, agar dapat membedakan citra. Citra yang dapat dikenali discriminator disebut sebagai citra palsu. Jadi, tugas discriminator adalah membedakan antara citra asli dan palsu (Winkler 2018) (M. Y. Liu and Tuzel 2016) (Creswell et al. 2018).

#### **2.3.4. DCGAN (Deep Convolutional Generative Adversarial Network)**

*Deep Convolutional Generative Adversarial Network* atau DC-GAN merupakan bagian atau perluasan dari arsitektur jaringan GAN. Hanya saja pada model jaringan DC-GAN, terdapat penggunaan layer Convolutional pada arsitektur diskriminatornya dan layer Transpose Convolutional pada layer generatornya (Secada Purba n.d.). Selain itu, pada arsitektur generator DC-GAN, aktivasi yang digunakan adalah ReLU untuk semua lapisan (kecuali pada lapisan output yang menggunakan tanH). Sedangkan pada arsitektur discriminator DC-GAN, menggunakan LeakyReLU untuk semua lapisan (Radford, Metz, and Chintala 2016). Terdapat juga penggunaan *Batch Normalization* yang berfungsi untuk meningkatkan kecepatan jaringan syarat tiruan dan agar lebih stabil (Secada Purba n.d.). DCGAN mulanya diperkenalkan dalam penelitian (Radford, Metz, and Chintala 2016). Selain itu, DCGAN dianggap memiliki menghasilkan



kualitas citra yang lebih baik bila dibandingkan dengan hasil sintesis citra menggunakan model GAN (B. Liu et al. 2022). Berikut adalah Gambar 2.2 terkait Arsitektur DCGAN



Gambar 2. 2 Arsitektur DCGAN

### 2.3.5. Fungsi Objektif GAN

Fungsi objektif yang digunakan dari struktur *Generative Adversarial Networks (GAN)* adalah sebagai berikut (Creswell et al. 2018)(Salimans et al. 2016):

$$\min_G \max_D V_{GAN}(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

Berikut adalah Tabel 1 terkait keterangan variable pada Fungsi objektif diatas, yaitu

Tabel 2. 2 Variabel Fungsi Objektif GAN

Variabel	Keterangan
G	Generator
D	Discriminator
x	Real data/ Citra
$p_x$	Distribusi dari x
$p_z$	Noise
D(x)	Hasil training Discriminator
G(z)	Hasil dari Generator
D(G(z))	Hasil discriminanator terhadap Citra Fake

Dalam proses training, discriminator akan memaksimalkan pemberian nilai terhadap nilai inputan dari generator dengan fungsi  $\log D(x) + \log(1 - D(G(z)))$ . Sedangkan Generator akan meminimalkan fungsi  $\log(1 - D(G(z)))$  untuk dapat menipu Diskriminator. Sehingga Generator akan berusaha dengan membuat citra mirip dengan dataset. Dan Diskriminator juga akan berusaha semaksimal mungkin mengidentifikasi hasil Generator untuk mengetahui palsu atau tidaknya citra tersebut.

### 2.3.6. Loss Function GAN

Loss function GAN dapat digunakan untuk mengukur sejauh mana performa dari model Generator dan Discriminator DCGAN. Proses pembelajaran GAN yaitu melatih Discriminator dan Generator secara bersamaan. Discriminator berusaha untuk memaksimalkan fungsi  $\log(1 - D(G(z)))$  dan akan meminimalkan fungsi  $D(G(z))$ . Sehingga fungsi loss function discriminator yaitu:

$$L^D = \text{Max} [\log D(x) + \log(1 - D(G(z)))] \dots \dots \dots (2)$$

Dengan fungsi diatas, discriminator akan berusaha memaksimalkan fungsi  $D(x)$  serta meminimalkan fungsi  $D(G(z))$ . Sehingga Generator harus berusaha kuat agar dapat menipu Diskriminator melalui hasil citra yang dibuat dengan cara meminimalkan fungsi  $\log(1 - D(G(z)))$  serta memaksimalkan fungsi  $G(z)$ .

$$L^G = \text{Min} [\log D(G(z))] \dots \dots \dots (3)$$

### 2.3.7. Latent Space Dimension

Latent space dimension pada GAN merupakan ruang yang dibentuk untuk menyimpan nilai array yang dibangkit secara acak dari distribution Gaussian tertentu (latent vector). Nilai array tersebut merupakan nilai-nilai yang terkompresi dari representasi suatu gambar yang memiliki dimensi tinggi. Nilai array yang tersimpan pada vektor dijadikan sebagai inputan pada jaringan Generator. Nilai array yang tersimpan pada vektor akan membentuk jalur linear antar vector pada latent space dimension sehingga akan menampilkan transisi diantara dua gambar. Pada penelitian sebelumnya, latent space dimension diatur pada nilai 100 (Mirza and Osindero 2014), nilai 512 oleh peneliti NVIDIA (Karras et al. 2018), 128 oleh (Brock, Donahue, and Simonyan 2019) serta latent vector dimensi dengan nilai 64 (Sáez Trigueros, Meng, and Hartnett 2021). Ukuran latent space dimension sangat penting dalam memungkinkan rekonstruksi data pelatihan yang akurat (Of et al. 2020).

### 2.3.8. Resnet152V2 model

ResNet model terdiri atas berbagai model dengan perbedaan masing-masing terdapat pada pooling layer dari model, seperti ResNet50 yang terdiri atas 50 Layers, ResNet101 terdiri atas 101 layers, ResNet152 dan ResNet152V2 terdiri dari 152 layers. Model ResNet152V2 terdiri atas 152 layer CNN yang telah dilatih menggunakan 1 juta citra (Lanjewar and Gurav 2022). ResNet152V2 merupakan jaringan residual yang dibangun oleh Kaiming He, et.al dan menghasilkan akurasi terbaik dibandingkan model ResNet yang ada (He et al. 2016).

### 2.3.9. VGG-16 and VGG-19 model

Jaringan arsitektur VGG terbukti bekerja lebih baik dibandingkan dengan arsitektur GoogleNet dalam hal multiple migration learning (Zhang, Lv, and Cheng 2020). Arsitektur VGG terdiri dari lapisan konvolusi yang diantaranya terdapat ReLU serta maxpolling sebagai penghubung layer dan diakhirnya terdapat fullu connected alyer untuk 1.000 kelas (Sandhopi, Lukman Zaman P.C.S.W, and Yosi Kristian 2020). Arsitektur VGG telah berkembang menjadi beberapa model, diantaranya VGG16 dan VGG19. VGG16 merupakan bagian arsitektur VGG yang terdiri atas 16 layer konvolusi, dimana 13 adalah layer konvolusional, 2 layer full connected, dan 1 layer softmax . Sedangkan VGG19 terdiri atas 19 layer, yaitu 16 layer konvolusi, 4 layer maxpooling, 2 layer full connected dan 1 layer softmax (Andrew and Santoso 2022). Berikut adalah Gambar 2.3 Arsitektur VGG16 dan VGG19



Gambar 2. 3 Arsitektur VGG16 dan VGG19

### 2.3.10. Xception Model

Xception (Extreme Inception) merupakan model arsitektur CNN yang dibuat oleh para peneliti dari Google. Merupakan pengembangan dari arsitektur


Inception yang tradisional serta terdiri atas 36 lapisan konvolusional dan membentuk basis jaringan untuk ekstraksi fitur. Lapisan tersebut dipisahkan jaringan residual yang saling berhubungan satu sama lain (Franc,ois Chollet; Google 2014). Xception dapat menghasilkan accuracy lebih tinggi daripada Inception dalam melakukan klasifikasi objek menggunakan database ImageNet sebanyak 17.000 citra (Leonardo et al. 2019). Berikut adalah Gambar 2. 4 arsitektur dari jaringan Xception Model



Gambar 2. 4 Arsitektur Exception Model

### 2.3.11. Inception ResNetV2 model


Inception ResNetV2 merupakan ragam dari model Inception V3 yang memiliki performa terbaik dari arsitektur Inception sebelumnya. Arsitektur ini menggabungkan jaringan Residual pada tahapan filter dari arsitektur Inception (Winarto, Rahmayati, and Lawi 2021). Koneksi dengan block residual akan membantu dalam meminimalisirkan waktu komputasi pelatihan jaringan serta menghilangkan distorsi citra yang disebabkan oleh struktur yang terlalu padat (Szegedy et al. 2017). Berikut adalah Gambar 2.5 Skema dari block Inception Resnet V2



Gambar 2. 5 Arsitektur Inception Resnet V2

### 2.3.12. DenseNet201 model

Dense Convolutional Network (DenseNet) memiliki variasi arsitektur diantaranya DenseNet121, DenseNet169, DenseNet201, dan DenseNet264. DenseNet hanya menggunakan sedikit parameter bila dibandingkan dengan parameter CNN yang bersifat konvensional (Huang et al. 2017). DenseNet201 terdiri atas 201 layer convolutional neural network dan telah menggunakan database ImageNet untuk proses pelatihannya. Model arsitektur tersebut telah mempelajari berbagai representasi fitur yang luas dari berbagai macam citra (Adhinata et al. 2021). Berikut adalah Gambar 2.6 arsitektur DenseNet201.



Gambar 2. 6 Arsitektur DenseNet201

### 2.3.13. Fréchet Distance of Inception (FID)

Untuk mengukur kualitas citra yang dibuat dengan menggunakan model GAN, dapat menggunakan dua teknik, yaitu *Quantitative Measure* dan *Qualitative Measure* (Venu and Ravula 2021). *Qualitative Measure* adalah pengukuran yang bersifat non-numerik, dimana pengukuran ini melibatkan nilai subjektif dari manusia dengan cara membandingkan hasil citra terhadap citra asli. Sedangkan *Quantitative Measure* adalah pengukuran yang bersifat numerik, melalui perhitungan score dari beberapa fungsi atau rumus, mengetahui dan mengevaluasi seberapa baik model yang dibuat. Contoh *Quantitative Measure* adalah Average Log-likelihood, Inception Score (IS), Fréchet Inception Distance (FID), Maximum Mean Discrepancy (MMD) dan lain sebagainya. Sedangkan *Qualitative Measure* adalah Nearest Neighbours, Rating and Preference Judgment, Evaluating Mode Drop dan Mode Collapse. Inception Score (IS) and Fréchet Distance of Inception (FID) adalah dua model evaluasi GAN yang banyak digunakan (Borji 2019). Pada penelitian ini, evaluasi model DCGAN menggunakan Fréchet Distance of Inception (FID).

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 (Heusel et al. 2017). 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 (Venu and Ravula 2021). Penelitian ini menghitung Fréchet Distance of Inception (FID) score menggunakan library python yang telah disediakan (pytorch-fid 2023).

#### 2.3.14. Evaluasi Performance Klasifikasi Citra

Untuk mengetahui dan mengevaluasi seberapa baik model yang dibuat, maka perlu diukur dengan sebuah ukuran yang disebut dengan metrics. Evaluation metrics sangat beragam, namun yang paling sering digunakan untuk mengukur model klasifikasi diantaranya adalah, accuracy, precision, dan F1-Score. Metrics-metrics tersebut dapat dilihat melalui tabel report yang disebut dengan *Confusion Matrix*. Confusion Matrix merupakan pengukuran performa yang menghasilkan atau mempresentasikan hasil proses klasifikasi yang terdiri atas True Positive (TP), True Negative (TN), False Postive (FP) dan Fakse Negatif (FN). Dari hasil presentasi tersebut, kita dapat menentukan nilai accuracy, precission, recal dan f1-score. Berikut ada Tabel 2.3 Metrics dari confusion matrix

Tabel 2. 3 Metrics Confusion

	Predicted Postive	Predicted Negative
Positive (actual)	True Postive (TP)	False Negative (FN)
Negative (actual)	False Negative (FP)	True Negative (TN)

Accuracy adalah rasio prediksi benar (Postive dan Negative) terhadap keseluruhan data. Untuk rumusnya adalah sebagai berikut :

$$Accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \dots \dots \dots (4)$$



Precision adalah rasion prediksi benar positif (TP) dibandingkan terhadap keseluruhan hasil prediksi yang bernilai positif (TP dan FP). Untuk rumusnya dapat dilihat sebagai berikut :

$$Precision = \frac{(TP)}{(TP + FP)} \dots \dots \dots (5)$$

Recall atau disebut dengan sensitivity, metrics yang mengcitrakan keberhasilan model dalam menemukan kembali sebuah informasi. Rumus dari Recall adalah sebagai berikut :

$$Recall = \frac{(TP)}{(TP + FN)} \dots \dots \dots (6)$$

F1-Score merupakan metrics yang mengcitrakan perbandingan rata-rata precision dan recall. Nilai terbaik F1-Score sebesar 1.0 dan nilai buruknya sebesar 0. F1-Score dapat mengindikasikan model klasifikasi baik menggantikan metrics accuracy. Rumus dari F1-Score dapat dilihat sebagai berikut :

$$F1\ Score = \frac{(2 \times Recall \times Precision)}{(Recall + Precision)} \dots \dots \dots (7)$$

## BAB III

### METODE PENELITIAN

#### 3.1. Jenis, Sifat, dan Pendekatan Penelitian

Jenis penelitian ini merupakan penelitian eksperimental, dimana peneliti melakukan proses pengumpulan data melalui studi literatur dan kemudian melakukan proses analisis data melalui hasil dari penelitian. Penelitian ini bersifat deskriptif, dimana penyajian citraan atau hasil analisis dijabarkan lengkap agar eksplorasi model terhadap sejumlah variable atau objek yang teliti menjadi lebih gampang dan mudah dipahami. Sedangkan untuk pendekatan yang digunakan dalam penelitian ini menggunakan pendekatan dengan metode kuantitatif, yang metode yang menggunakan informasi numerik pada hasil testing data yang kemudian akan menjadikan perbandingan data dengan sumber relevan..


#### 3.2. Metode Pengumpulan Data

Dalam penelitian ini, peneliti menggunakan data dari dataset citra tanah yang sebelumnya telah digunakan dalam penelitian sebelumnya (Lanjewar and Gurav 2022). Dataset tersebut terdiri atas 903 citra yang terbagi menjadi 4 kategori atau jenis tanah, yaitu Alluvial Soil, Red Soil, Clay Soil dan Black Soil. Jumlah data untuk masing-masing jenis tanah dapat dilihat pada Tabel 3.1 Jumlah Dataset Tanah dibawah ini:

Tabel 3. 1 Jumlah Dataset

NO	JENIS TANAH	JUMLAH
1	Alluvial Soil	223
2	Red Soil	230
3	Black Soil	259
4	Clay Soil	191
	<b>Total Data</b>	903

Berdasarkan tabel diatas, diketahui terjadi *imbalance* data pada setiap jenis tanah. Data citra paling sedikit terdapat pada jenis Clay Soil dan paling terbanyak berada pada data Black Soil. Berikut Gambar 3.1 adalah data citra dari masing-masing jenis tanah.




Gambar 3. 1 Dataset

Clay soil atau tanah liat yang didapatkan pada dataset adalah tanah liat yang telah mengering. Red soil didominasi dengan warna merah orange. Alluvial soil

didominasi dengan warna kuning kecoklatan. Dan Black soil didominasi warna hitam

### 3.3. Metode Augmentasi Data

Augmentasi data pada penelitian ini menggunakan model *DCGAN* yang berbeda dari penelitian sebelumnya, (Lanjewar and Gurav 2022), yang menggunakan proses augmentasi tradisional dalam proses klasifikasi gambar. Terdapat dua jaringan yang dibangun dalam model *DCGAN* yaitu jaringan generator dan jaringan discriminator. Pada jaringan generator menggunakan layer *convolutional transpose (Convo2dTranpose)* yang terdiri atas empat layer *Conv2DTransposes* sedangkan pada jaringan diskrimantor menggunakan layer convolution *Conv2D* yang terdiri atas 4 layer. Jaringan generator menggunakan aktivasi *Rectified Linear Unit (ReLU)* untuk setiap layer kecuali pada layer terakhir menggunakan fungsi tanh. Sedangkan layer diskrimantor menggunakan 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 yang digunakan adalah 128x128x3 dengan epoch percobaan yaitu 1000. Berikut adalah Gambar 3.2 Arsitektur jaringan Generator dan Gambar 3.3 Arsitektur jaringan Discriminator pada model *DCGAN* yang digunakan dalam penelitian ini



Gambar 3. 2 Arsitektur Jaringan Generator



Gambar 3. 3 Arsitektur Jaringan Discriminator

### 3.4. Metode Analisis Data

Penelitian ini menggunakan Bahasa pemrograman python dengan tools aplikasi pemrograman adalah Google Colab Pro. Analisis data dilakukan dengan mendeskripsikan secara analitik data yang didapatkan dari hasil evaluasi metode, menggunakan *FID Score* dan *confusion matrix*. Hasil *Score Fre'chet Inception Distance* (FID) digunakan untuk mengukur hasil gambar sintesis yang dibuat menggunakan metode DCGAN. Sedangkan evaluasi model CNN untuk proses

klasifikasi menggunakan confusion matrix. Penggunaan library dapat membantu memudahkan dalam interpretasi data.

### 3.5. Alur Penelitian

Alur penelitian yang dibuat dalam penelitian terdiri atas beberapa tahapan, dimulai dari studi literatur atau pustaka yang memiliki keterkaitan dengan penelitian yang akan dilakukan. Tahapan selanjutnya yaitu Pengumpulan data atau dataset yang digunakan untuk bahan penelitian. Dari pengumpulan data selanjutnya ke tahapan membangun model yang digunakan dalam penelitian. Model yang telah dibangun kemudian di training lalu di testing hingga mendapatkan hasil. Hasil dari penelitian tersebut kemudian di analisis dalam tahapan analisis penelitian, dan terakhir tahapan membuat laporan dari hasil analisis dari penelitian yang telah dilakukan. Alur penelitian yang dibuat untuk penelitian dapat dilihat pada Gambar 3.2. Alur Penelitian, yang menjadi kontribusi dalam penelitian ini yaitu menggunakan augmentasi sintesis pada proses klasifikasi citra yang ditunjukkan pada bagian yang diberikan garis merah. Serta Model CNN yang dicoba buat sendiri untuk meningkatkan performa klasifikasi citra tanah menggunakan citra sintesis tersebut. Untuk lebih jelasnya berikut adalah penjelasan dari tahapan-tahapn alur penelitian.

#### a. Studi Literatur

Pada tahap ini, peneliti melakukan penggalian informasi serta data untuk bahan penelitian. Penggalian informasi dilakukan dengan cara mencari literatur-literatur terdahulu atau sebelumnya yang memiliki keterkaitan dengan penelitian yang akan dilakukan.

#### b. Pengumpulan Data

Selanjutnya, dilakukan tahapan pengumpulan data. Pengumpulan data dilakukan melalui proses pengunduhan citra tanah yang merupakan dataset dari penelitian sebelumnya dengan objek yang sama. Data yang didapatkan terlebih dahulu di *preprocessing* sebelum digunakan dalam model. Hal ini dikarenakan data yang didapatkan memiliki variasi ukuran citra serta tipe data citra yang berbeda. Tipe citra yang didapatkan pada dataset mentah terdiri atas tipe jpg dan webp. Sehingga data citra yang bertipe webp terlebih dahulu diubah ke jpg menggunakan aplikasi bantuan yaitu *Bitmap*. Hal tersebut perlu dilakukan agar data citra memiliki format yang sama dan dapat diproses dalam proses codingan.

#### c. Membangun Model

Pada tahap ini, dilakukan proses pemodelan data dengan tools GoogleColab. Pemodelan yang dibuat terdiri atas dua, yaitu pemodelan untuk membuat citra sintesis menggunakan DCGAN Model yang dapat dilihat pada Gambar 3.3 Alur penelitian, bagian yang telah diberi kotak kuning. Dan juga pemodelan untuk melakukan klasifikasi data citra menggunakan beberapa arsitektur dari CNN Model yang dapat dilihat pada Gambar 3.3 Alur penelitian yang diberi kotak kuning. Tahap ini merupakan bagian dari kontribusi peneliti dalam penelitian klasifikasi jenis tanah.

Model yang terlebih dahulu dibuat adalah model untuk menghasilkan citra sintesis dengan cara augmentasi. Tujuannya adalah untuk menyamakan jumlah data citra pada setiap kategori. Citra sintesis yang telah dihasilkan dari model DCGAN akan digabungkan dengan dataset lama sebagai tambahan data untuk

proses klasifikasi citra.

Selanjutnya, data gabungan tersebut ditraining menggunakan model CNN untuk melakukan klasifikasi citra yang terdiri dari InceptionResNet, DenseNet201, Xception, VGG16, VGG19 dan ResNet152V2. Peneliti juga mencoba melakukan klasifikasi dengan menggunakan model CNN yang dibangun sendiri untuk dijadikan sebagai kontribusi berikut dalam hal peningkatan performa klasifikasi citra menggunakan dataset citra sintesis. Sebelum dilakukannya proses training, data terlebih dibagi menjadi data training dan data testing dengan proporsi pembagian yaitu 80:20.

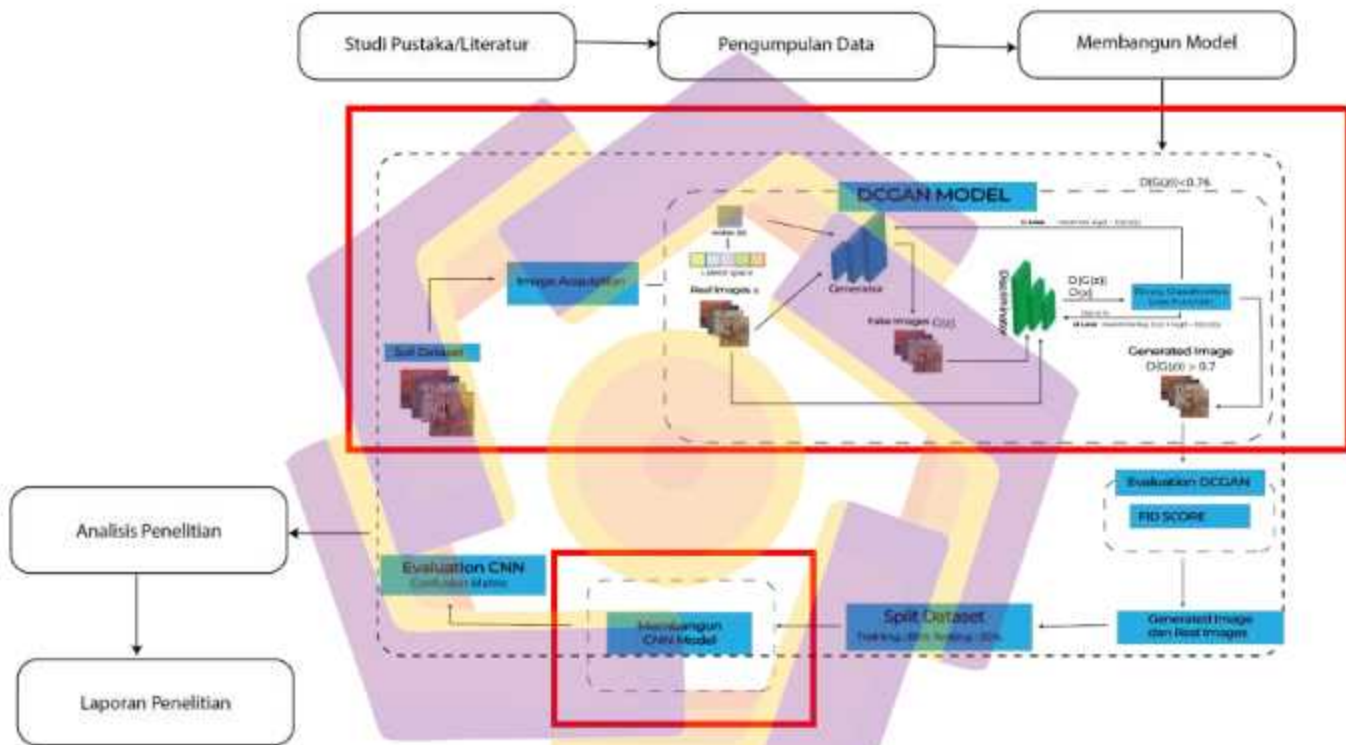
d. Analisis Penelitian

Model yang telah ditraining kemudian ditesting atau diuji untuk dianalisis performa hasilnya. Untuk penelitian ini digunakan dua metode pengujian, yaitu metode pengujian hasil model DCGAN untuk mengetahui tingkat kemiripan antara citra sintesis dengan citra asli. Serta metode pengujian model klasifikasi terhadap akurasi model dalam mengenali atau mengklasifikasi citra. Hasil model untuk klasifikasi citra kemudian akan dibandingkan dengan penelitian sebelumnya.

e. Laporan Penelitian

Pada tahap ini, dilakukan dokumentasi atas hasil pengujian untuk dijabarkan dalam bentuk kesimpulan serta pembuatan laporan penelitian





Gambar 3. 4 Alur Penelitian

## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

#### 4.1. Augmentasi Data

Untuk menyeimbangkan kategori pada dataset tanah serta memperbanyak data, maka digunakan data sintesis menggunakan model DCGAN. Peneliti membangun model DCGAN dengan menggunakan parameter yang telah disebutkan pada Bab III. Pada penelitian ini, pengujian melakukan percobaan pada *latent space dimension*, yaitu ruang berisikan *vector* acak yang digunakan untuk membuat gambar sintesis oleh jaringan generator. *Latent space* berfungsi untuk menyimpan informasi penting dari sebuah citra yang telah terkompresi. Artinya, *latent space* akan menyerdehanakan representasi data/citra dengan tujuan untuk menemukan suatu pola. Terdapat lima kali skenario percobaan dalam menghasilkan dataset sintesis, sesuai dengan nilai *latent space dim(z)* yang diujicoba, yaitu: 64, 100, 128, 256 dan 512. Nilai *latent space* tersebut merupakan nilai ukuran ruang dimensi yang digunakan untuk menyimpan nilai array dari kumpulan representasi citra dari dataset yang berdimensi tinggi. Kemudian dengan adanya noise serta melalui jaringan generator, nilai array tersebut diubah menjadi nilai array baru yang mempresentasikan citra sintesis baru yang menyerupai citra lama.

Untuk inputan citra pada jaringan generator adalah  $128 \times 128 \times 3$  dengan output gambar yang dihasilkan dari jaringan discriminator juga sebesar  $128 \times 128 \times 3$ . Berikut adalah Skema proses augmentasi data menggunakan model DCGAN.

Pada model DCGAN yang dibuat, baik pada arsitektur Generator maupun Discriminator, tidak ditambahkan layer *BatchNormalization* seperti model DCGAN yang dibuat oleh penelitian sebelumnya. Hal ini dikarenakan, berdasarkan hasil percobaan yang dibuat, citra sintesis yang diperoleh tidak menyerupai citra tanah. Citra sintesis yang dihasilkan berupa gambar dengan warna abu-abu solid.

Berdasarkan Gambar 3.3. Alur Penelitian, jaringan generator akan membuat citra tanah palsu sesuai dengan noise yang diberikan output citra dari generator dilambangkan dengan  $G(z)$ . Selanjutnya, citra tanah palsu tersebut bersamaan dengan citra asli tanah yang berlabel  $(x)$ , masuk ke jaringan *discriminator*. Hal tersebut yang mengakibatkan proses training pada model DCGAN menjadi lama. Selanjutnya, kedua gambar tersebut akan divalidasi oleh jaringan *discriminator*. Output dari jaringan *discriminator*  $D(G(z))$  dan  $D(x)$  dengan nilai threshold yaitu 0 dan 1. Jaringan *discriminator* akan dapat dikatakan berhasil membedakan citra asli dan citra palsu apabila nilai threshold  $D(G(z))=0$ , dan  $D(x)=1$ , menandakan jaringan *discriminator* mampu membedakan mana citra asli dan mana citra yang palsu, dengan artian jaringan *discriminator* telah bekerja sesuai dengan prosedur. Untuk citra yang dijadikan dataset adalah citra palsu yang menyerupai citra asli, dalam arti nilai  $D(G(z))$  harus mendekati nilai satu. Pada penelitian ini, nilai  $D(G(z))$  yang digunakan pada citra sintesis yaitu  $> 0.75$ . Pemilihan nilai tersebut karena, berdasarkan hasil percobaan, apabila nilai yang  $D(G(z)) > 0,8$ , gambar yang dihasilkan sangat sedikit untuk epoch 1K. Perlu adanya penelitian yang membahas penentuan nilai  $D(G(z))$ .

Untuk membuat satu citra menggunakan model DCGAN, generator akan menggabungkan warna dari kumpulan citra. Sehingga kita tidak bisa mengetahui citra asli mana saja yang membentuk atau menghasilkan citra sintesis.

#### 4.2. Evaluasi Data Sintesis


Citra yang terdapat pada dataset digunakan untuk membuat citra sintesis baru dengan menambahkan jumlah data pada dataset tanah sebelumnya. Dari penetapan nilai  $D(G(z)) > 0.75$ , dataset yang semula berjumlah 903, ditambah hingga menjadi 2000 citra dengan jumlah penambahan citra pada setiap kategori adalah sebagai berikut :

Tabel 4. 1 Jumlah Data Hasil Augmentation

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 4.1 diatas, penambahan citra sebanyak 1097 dari total citra awal yang terbagi 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.

Proses augmentasi data menggunakan model DCGAN dilakukan dengan melakukan perubahan terhadap nilai parameter latent space dimension  $dim(z)$ . Nilai parameter latent space dimension yang digunakan yaitu 64, 100, 128, 256 dan 512.



Gambar 4. 1 Hasil Augmentasi dengan variasi latent space dimension  $\dim(z) \in \{64, 100, 128, 256, 512\}$

Gambar 4.1 adalah citra hasil Augmentasi menggunakan model DCGAN dengan variasi latent space dimension  $\dim(z) \in \{64, 100, 128, 256, 512\}$ . Pada gambar tersebut inputan citra yang digunakan berukuran 128x128. Gambar 4.1 (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 4.1 (b) nilai parameter latent space yang digunakan adalah 100. Pada Gambar 4.1 (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 4.1 (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 4.1 (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 kotak 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 4.1 (e), citra sintesis tanah yang dibuat dengan menggunakan nilai latent space dimension 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

Selanjutnya, citra hasil augmentasi akan dievaluasi menggunakan metode Fre'chet Inception Distance (FID). Hal tersebut dilakukan untuk menguji efek dimensi ruang latent pada citra sintesis yang dihasilkan. Score terkecil dari FID menunjukkan model GAN yang lebih baik (Venu and Ravula 2021). Pada penelitian ini, peneliti menggunakan library python untuk menghitung nilai FID pada citra sintesis dengan latent space dimensi yang berbeda-beda. Perhitungan score FID dilakukan dengan dua kali percobaan. Percobaan pertama dengan menghitung score FID pada masing-masing kategori citra dengan latent space dimension yang berbeda-beda. Percobaan kedua yaitu dengan menggabungkan

folder citra yang memiliki kesamaan latent space dimensi dan kemudian dihitung secara kolektif. Hasil perhitungan pada percobaan pertama dapat dilihat pada Tabel 4.2 Hasil Score FID per Kategori dibawah ini

Tabel 4. 2 Hasil Score FID Per Kategori  
 $\dim(z) \in \{64, 100, 128, 256, 512\}$

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

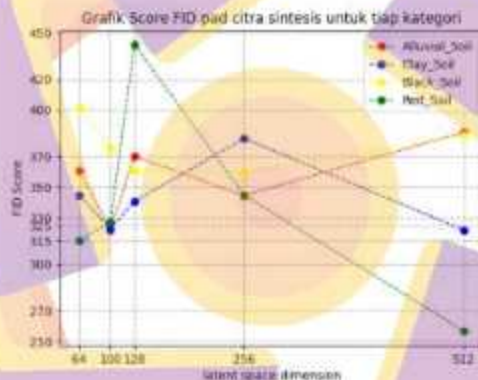
Berdasarkan Tabel 4.2 diatas, untuk latent space dimension bernilai 64, diketahui score tertinggi dimulai dari black soil, alluvial soil, clay soil dan red soil. Padahal jika dilihat kembali pada Gambar 4.1. (a), citra sintesis yang terlihat kurang bagus adalah alluvial soil dan clay soil. Sedangkan 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 4.1. (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 4.1 (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 4.3 Grafik score FID hasil citra sintesis untuk setiap kategori tanah menggunakan latent space dimension yang berbeda-beda.



Gambar 4. 2 Grafik Score FID setiap kategori gambar

Berdasarkan gambar grafik diatas, disimpulkan bahwa untuk citra kategori alluvial memiliki kualitas citra terbagus 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. 3 Hasil Score FID per Dataset

Latent space dimensi dim ( $z$ )	Hasil FID Score
64	287,61
100	267,39
128	310,96
256	290,58
512	275,76

Jika melihat tabel diatas, hasil pengujian pembuatan dataset sintesis, diperoleh penggunaan nilai latent space dimension yang menghasil kualitas citra terbaik adalah 128. Dimana score terkecil dari FID menunjukkan model GAN yang lebih baik dalam menghasilkan citra (Venu and Ravula 2021) Score FID terkecil yang diperoleh adalah 267,39 dengan penggunaan nilai latent space dimension yaitu 100. Namun, apabila dilihat pada Gambar 4.1 (a), (b), (c), (d) dan (e), menurut pengamatan penelitian, citra sintesis yang memiliki kualitas bagus adalah dengan menggunakan latent space dimension 128. Pada citra hasil penggunaan latent space dimension tersebut, tidak banyak terlihat pixel pada gambar yang blur. Hanya saja, penilaian dengan cara pengamatan langsung adalah penilian yang bersifat relative, artinya boleh jadi, masing-masing peneliti dapat

memiliki perbedaan pendapat dalam menentukan citra yang memiliki kualitas bagus.

#### 4.3. Evaluasi Performa Klasifikasi CNN

Sebelum diproses ke tahapan klasifikasi, data citra sintesis terlebih dahulu digabungkan dengan citra awal untuk menjadi dataset yang baru. Terdapat 5 dataset yang akan dibentuk dalam penelitian ini, yaitu dataset dengan citra yang menggunakan latent space dimensi  $\dim(z)$  bernilai 64, 100, 128, 256 dan 512. Masing-masing dataset tersebut kemudian displit untuk proses training dan testing dengan perbandingan 80:20 citra. Berikut Tabel 4.4 jumlah citra dalam pembagian dataset.

Tabel 4. 4 Pembagian Daaset

Kategori	Data Training	Data Testing
Alluvial Soil	400 citra	100 citra
Clay Soil	400 citra	100 citra
Black Soil	400 citra	100 citra
Red Soil	400 citra	100 citra
Total Data	1600	400 citra

Pada penelitian ini, juga akan diuji efek dari dataset baru yang telah terbentuk terhadap performa beberapa arsitektur CNN. Beberapa arsitektur CNN yang digunakan adalah ResNet152V2, VGG16, VGG19, Xception, Inception ResNetV2, DenseNet20 serta model CNN yang dibuat sendiri. Pada setiap arsitektur menggunakan fungsi optimizer *Adamax* dan *learning rate* = 0,0001. Berikut ini adalah pembahasan hasil evaluasi dari masing-masing arsitektur CNN yang digunakan untuk melakukan klasifikasi terhadap dataset.

#### 4.2.1. Hasil Evaluasi pada Arsitektur ResNet152V2

Berikut ini adalah Tabel 4.5 yang menunjukkan performance metrics dari arsitektur ResNet152V2 pada setiap dataset  $\text{dim}(z)$  yang digunakan. Performance metrics yang digunakan adalah *Accuracy*, *Precision*, *Recall* dan *F1-Score*. Performa terbaik didapatkan pada penggunaan dataset latent space dimension 128, dimana nilai akurasi sebesar 97%, *precision* 98%, *recall* 97% dan *F1-Score* 98%. Disusul terbaik kedua, pada penggunaan dataset *latent space dimension* 100 dan 256. Keduanya memiliki nilai yang sama, yaitu nilai akurasi 97%, *precision* 97%, *recall* 97% dan *f1-score* 97%. Terbaik ketiga didapatkan pada penggunaan *latent space dimension* 64, dimana nilai akurasi 96%, *precision* 97%, *recall* 97% dan *f1-score* 96%. Dan terakhir adalah penggunaan *latent space dimension* 512 yang mendapatkan nilai akurasi sebesar 96%, *precision* 96%, *recall* 96% dan *f1-score* juga 96%.

Tabel 4.5 Performance Metrics Arsitektur ResNet152V2

Metrics	Dataset dengan latent space dimensi $\text{dim}(z)$				
	64	100	128	256	512
Accuracy	96	97	97	97	96
Precision	97	97	98	97	96
Recall	97	97	97	97	96
F1-Score	96	97	98	97	96

Selanjutnya, confusion matrix pada arsitektur ResNet152V2 untuk tiap dataset dengan latent space dimensi berbeda ditunjukkan pada Gambar 4.3 (a), (b), (c), (d) dan (e). Pada gambar 4.3 (a) hasil confusion matrix menggunakan dataset berlatent space dimension 64, didapatkan sebanyak 4 citra kategori alluvial yang diprediksi salah, satu citra diprediksi sebagai black soil dan 3 citra diprediksi sebagai red soil. Selanjutnya, terdapat 5 citra kategori black soil diprediksi salah, dimana satu citra diprediksi alluvial soil, 2 citra diprediksi sebagai clay soil dan 1

citra diprediksi sebagai red soil. Hanya satu citra kategori clay soil yang diprediksi salah sebagai kategori alluvial soil. Dan 5 citra kategori red soil yang diprediksi salah, terdiri dari 3 citra yang diprediksi sebagai alluvial soil, 1 citra diprediksi sebagai black soil, dan 1 citra diprediksi sebagai clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 15 citra.

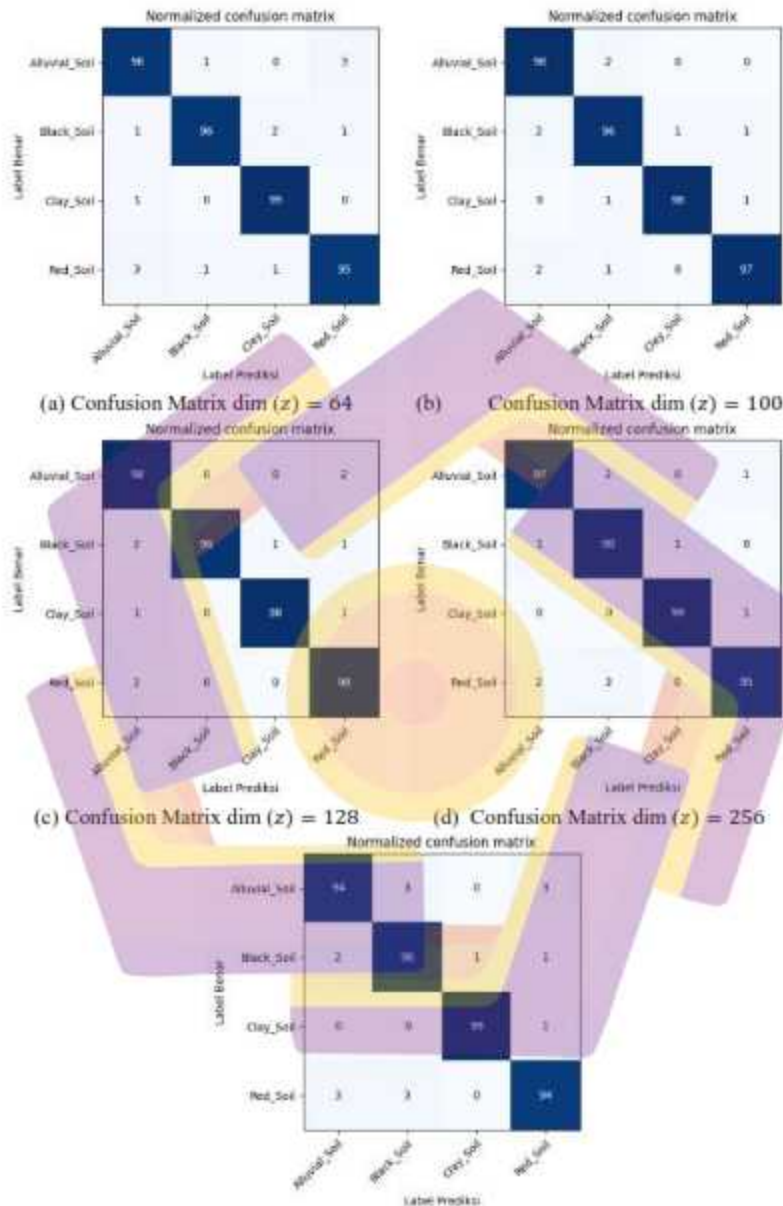
Selanjutnya untuk Gambar 4.3 (b) hasil confusion matrix menggunakan dataset *latent space dimension* 100. Diperoleh sebanyak 2 citra kategori alluvial yang diprediksi salah sebagai black soil. Terdapat 4 citra kategori black soil diprediksi salah, 2 diprediksi alluvial soil, 1 diprediksi clay soil dan 1 citra lagi diprediksi red soil. Ada 2 citra kategori clay soil yang diprediksi salah, 1 citra diprediksi black soil dan 1 citra diprediksi red soil. Dan terakhir, ada 3 citra kategori red soil yang diprediksi salah, terdiri atas 2 citra diprediksi sebagai alluvial, dan satu diprediksi sebagai black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 11 citra.

Untuk Gambar 4.3 (c) yang menggunakan dataset *latent space dimension* 128, diperoleh hasil *confusion matrix* yaitu sebanyak 2 citra kategori alluvial yang diprediksi salah sebagai red soil. Kemudian ada 4 citra kategori black soil diprediksi salah, terdiri dari 2 citra diprediksi alluvial soil, 1 citra diprediksi clay soil dan 1 citra lagi diprediksi sebagai red soil. Berikutnya ada 2 citra kategori clay soil yang diprediksi salah, yaitu 1 citra diprediksi sebagai alluvial soil, dan 1 citra lagi diprediksi sebagai red soil. Terakhir, 2 citra kategori red soil yang diprediksi salah sebagai alluvial soil. Jadi, total keseluruhan citra yang diprediksi

salah tidak sesuai dengan labelnya adalah 10 citra, lebih sedikit kesalahan bila dibandingkan dengan hasil sebelumnya.

Berikutnya pada Gambar 4.3 (d) hasil confusion matrix menggunakan dataset *latent space dimension* 256. Terdapat 3 citra kategori alluvial yang diprediksi salah, yaitu 2 citra diprediksi sebagai black soil dan 1 diprediksi sebagai red soil. Berikutnya terdapat 2 citra kategori black soil yang diprediksi salah, satu citra diprediksi sebagai alluvial soil dan 1 citra lagi diprediksi clay soil. Selanjutnya, hanya 1 citra kategori clay soil diprediksi salah sebagai red soil. Dan terakhir, sebanyak 5 citra kategori red soil yang diprediksi salah, 2 citra diprediksi sebagai *alluvial soil* dan 3 citra lainnya diprediksi sebagai black soil. Sehingga total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya ada 11 citra juga. Dan terakhir untuk Gambar 4.3 (e) yang menggunakan dataset *latent space dimension* 512, diperoleh hasil confusion matrix yaitu sebanyak 6 citra kategori alluvial yang diprediksi salah, yaitu 3 citra diprediksi black soil dan 3 citra lainnya diprediksi sebagai red soil. Kemudian, 4 citra kategori black soil diprediksi salah, yaitu 2 citra diprediksi alluvial soil, 1 citra diprediksi clay soil dan 1 citra red soil. Terdapat 1 citra kategori clay soil yang diprediksi salah sebagai red soil. Dan ada 6 citra kategori red soil yang diprediksi salah, yaitu 3 citra diprediksi sebagai alluvial soil, dan 3 citra lagi diprediksi sebagai black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya ada 17 citra, lebih banyak dibandingkan hasil confusion matrix pada latent space dimension sebelumnya.

Dari lima dataset yang diuji coba di atas, dengan menggunakan arsitektur ResNet152V2, diperoleh performa terbaik ketika menggunakan dataset I28.



Gambar 4. 3 Confusion Metrics Arsitektur ResNet152V2

#### 4.2.2. Hasil Evaluasi pada Arsitektur VGG16

Berikut ini adalah Tabel 4.6 yang menunjukkan performance metrics dari arsitektur VGG16 pada setiap latent space dimension yang digunakan. Performa terbaik didapatkan pada penggunaan dataset berlatent space dimension 128, dimana nilai akurasi sebesar 97%, precision 97%, recall 97% dan F1-Score 97%. Performa terbaik kedua, didapatkan pada penggunaan dataset berlatent space dimension 256 yang memiliki nilai akurasi 96%, precision 96%, recall 96% dan f1-score 96%. Terbaik ketiga didapatkan pada penggunaan latent space dimension 100 dan 512, dimana keduanya memiliki nilai yang sama yaitu nilai akurasi 95%, precision 95%, recall 95% dan f1-score 95%. Dan performa terendah terdapat pada penggunaan latent space dimension 64 yang mendapatkan nilai akurasi sebesar 93%, precision 93%, recall 93% dan f1-score juga 93%.

Tabel 4. 6 Performance Metrics Arsitektur VGG16

Metrics (%)	Latent space dimensi $\dim(z)$				
	64	100	128	256	512
Accuracy	93	95	97	96	95
Precision	93	95	97	96	95
Recall	93	95	97	96	95
F1-Score	93	95	97	96	95

Selanjutnya, confusion matrix pada arsitektur VGG16 untuk tiap dataset dengan latent space dimensi berbeda ditunjukkan pada Gambar 4.4 (a), (b), (c), (d) dan (e). Pada gambar 4.4 (a) hasil confusion matrix menggunakan dataset *latent space dimension* 64, didapatkan sebanyak 9 citra kategori alluvial yang diprediksi salah, terdiri atas 2 citra diprediksi sebagai black soil dan 7 citra diprediksi sebagai red soil. Kemudian, 6 citra kategori black soil diprediksi salah, terdiri dari 2 citra diprediksi sebagai alluvial soil, dan 4 citra diprediksi sebagai

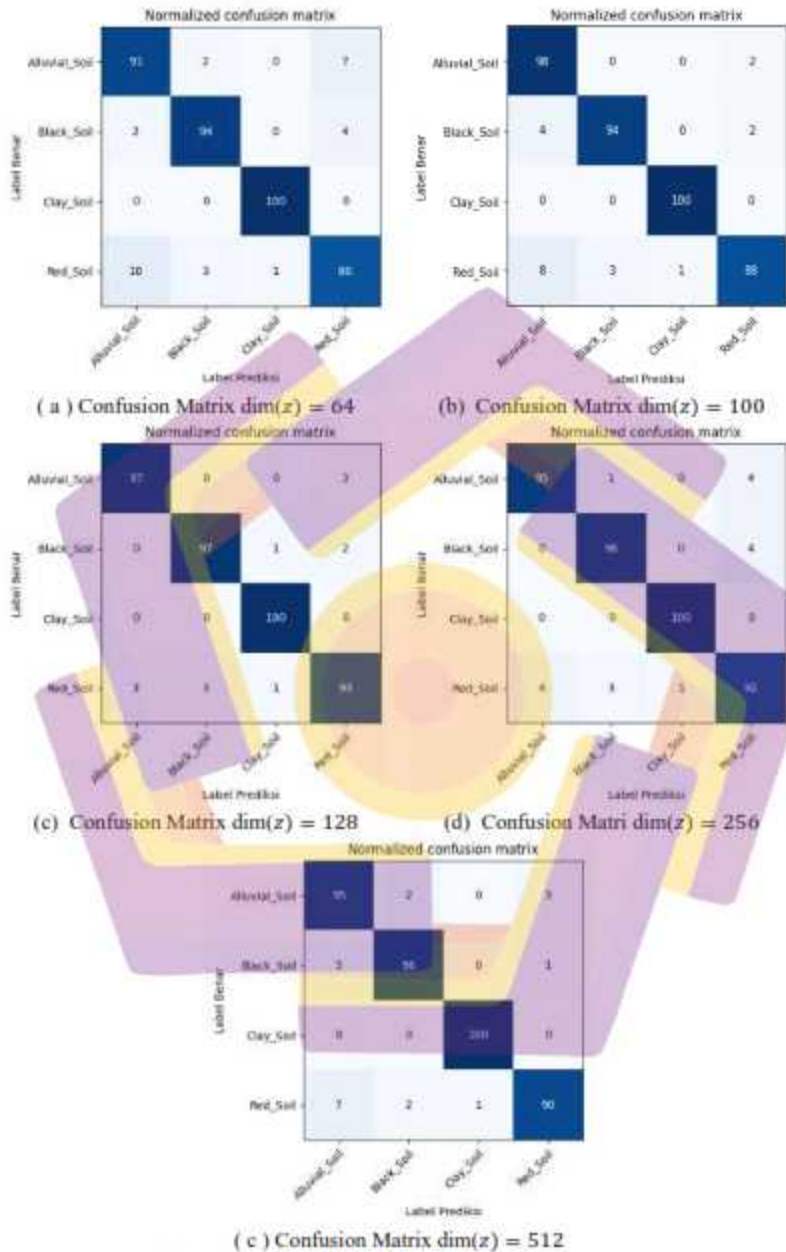


red soil. Citra kategori clay soil diprediksi benar semua. Dan citra red soil yang diprediksi salah sebanyak 14 citra, 10 citra diprediksi alluvial soil, 3 citra diprediksi black soil dan 1 citra diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 29 citra.

Selanjutnya untuk Gambar 4.4 (b) hasil confusion matrix menggunakan dataset *latent space dimension* 100. Diperoleh sebanyak 2 citra kategori alluvial yang diprediksi salah sebagai red soil. Terdapat 6 citra kategori black soil diprediksi salah, yaitu 4 citra diprediksi alluvial soil dan 2 citra diprediksi red soil. Selanjutnya 12 citra kategori red soil yang diprediksi salah, yaitu 10 citra diprediksi alluvial soil, 3 citra diprediksi black soil dan 1 citra diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 20 citra.

Untuk Gambar 4.4 (c) yang menggunakan dataset *latent space dimension* 128, diperoleh hasil confusion matrix yaitu sebanyak 3 citra kategori alluvial diprediksi salah sebagai red soil. Terdapat 3 citra juga kategori black soil yang diprediksi salah, yaitu 2 diprediksi red soil dan 1 citra diprediksi clay soil. Selanjutnya, 7 citra kategori red soil yang diprediksi salah terdiri dari 3 citra yang diprediksi sebagai alluvial dan 3 citra diprediksi sebagai black soil dan 1 citra diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 13 citra,

Berikutnya pada Gambar 4.4 (d) hasil confusion matrix menggunakan dataset *latent space dimension* 256. Terdapat 5 citra kategori alluvial yang diprediksi salah, yaitu 4 citra kategori red soil dan 1 citra kategori black soil.



Gambar 4.4 Confusion Metrics Arsitektur VGG16

Berikutnya terdapat 4 citra kategori black soil diprediksi salah sebagai red soil. Dan 8 citra kategori red soil yang diprediksi salah terdiri dari 4 citra diprediksi sebagai alluvial soil, 3 citra diprediksi black soil dan 1 citra diprediksi sebagai clay soil. Sehingga total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya ada 17 citra juga.

Dan terakhir untuk Gambar 4.4 (e) yang menggunakan dataset latent space dimension 512, diperoleh hasil confusion matrix yaitu sebanyak 5 citra kategori alluvial yang diprediksi salah, terdiri atas 2 citra diprediksi black soil dan 3 citra diprediksi red soil. Kemudian 4 citra kategori black soil diprediksi salah, terdiri atas 3 citra diprediksi alluvial soil dan 1 citra diprediksi red soil. Selanjutnya ada 10 citra kategori red soil yang diprediksi salah, 7 citra diprediksi alluvial soil, 2 citra diprediksi black soil dan 1 diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 19 citra.

Jadi dari kelima dataset yang diuji coba diatas, terlihat bahwa arsitektur VGG16 dapat menghasilkan klasifikasi terbaik dengan menggunakan dataset 128

#### 4.2.3. Hasil Evaluasi pada Arsitektur VGG19

Pada Tabel 4.7 berikut menunjukkan performance metrics menggunakan arsitektur VGG19 pada setiap latency space dimension yang digunakan.

Tabel 4. 7 Performance Metrics Arsitektur VGG19

Metrics (%)	Latent space dimensi dim (x)				
	64	100	128	256	512
Accuracy	95	95	95	95	95
Precision	95	95	95	95	95
Recall	95	95	95	95	95
F1-Score	95	95	95	95	95

Jika dilihat pada tabel diatas, pada arsitektur VGG19, tidak ada perbedaan nilai untuk hasil performance metrics pada setiap latency space dimension yang digunakan. Setiap latent space dimension memiliki nilai akurasi, precision, recall dan f1-score yang sama yaitu 95%.

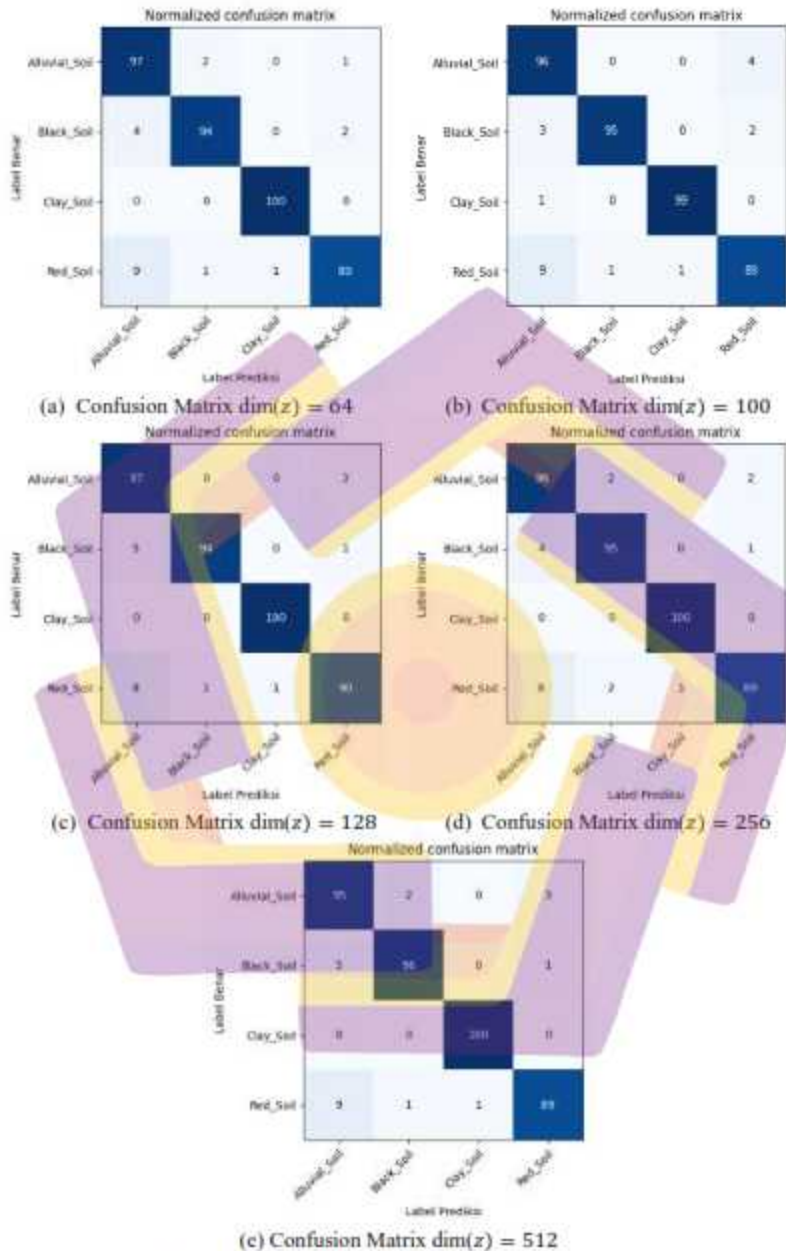
Hasil confusion matrix pada arsitektur VGG19 untuk tiap dataset dengan latent space dimensi berbeda dapat dilihat pada Gambar 4.5 (a), (b), (c), (d) dan (e). Pada gambar 4.5 (a) hasil confusion matrix menggunakan dataset latent space dimension 64, didapatkan sebanyak 3 citra kategori alluvial yang diprediksi salah, yaitu 2 citra diprediksi black soil dan 1 citra diprediksi red soil. Selanjutnya 6 citra kategori black soil diprediksi salah, terdiri dari 4 citra diprediksi alluvial soil dan 2 citra diprediksi red soil. Citra kategori clay soil diprediksi benar semua. Dan 11 citra red soil diprediksi salah terdiri atas 9 citra diprediksi alluvial soil, 1 citra diprediksi black soil dan 1 citra lagi diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 20 citra.

Selanjutnya untuk Gambar 4.5 (b) hasil confusion matrix menggunakan dataset berlatent space dimension 100. Diperoleh sebanyak 4 citra kategori alluvial yang diprediksi salah. Sebanyak 5 citra kategori black soil diprediksi salah, terdiri atas 3 citra alluvial soil dan 2 citra black soil. Kemudian hanya 1 citra clay soil diprediksi salah sebagai alluvial soil, dan 11 citra kategori red soil yang diprediksi salah terdiri atas 9 citra diprediksi alluvial, 1 citra diprediksi black soil, dan 1 citra diprediksi sebagai clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 21 citra. Untuk Gambar 4.5 (c) yang menggunakan dataset berlatent space dimension 128, diperoleh hasil confusion matrix yaitu

sebanyak 3 citra kategori alluvial yang diprediksi salah sebagai red soil. Selanjutnya 6 citra kategori black soil diprediksi salah, terdiri dari 5 citra diprediksi sebagai alluvial soil dan 1 citra diprediksi sebagai red soil. Dan 10 citra kategori red soil yang diprediksi salah, terdiri dari 8 citra diprediksi alluvial soil, 1 citra diprediksi black soil dan 1 citra lagi diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 19 citra,

Berikutnya pada Gambar 4.5 (d) hasil confusion matrix menggunakan dataset berlatent space dimension 256. Terdapat 4 citra kategori alluvial yang diprediksi salah, masing-masing sebanyak 2 citra diprediksi black soil dan red soil. Lalu ada 5 citra kategori black soil diprediksi salah, yaitu 4 citra diprediksi alluvial soil dan 1 citra diprediksi red soil. Dan 11 citra kategori red soil yang diprediksi salah, terdiri dari 8 citra diprediksi alluvial soil, 2 citra diprediksi black soil dan 1 citra lagi diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 20 citra.

Dan terakhir untuk Gambar 4.5 (e) yang menggunakan dataset berlatent space dimension 512, diperoleh hasil confusion matrix yaitu sebanyak 5 citra kategori alluvial yang diprediksi salah terdiri dari 2 citra diprediksi alluvial soil, dan 3 citra diprediksi red soil. Lalu terdapat 4 citra kategori black soil diprediksi salah, yaitu 3 citra diprediksi alluvial soil dan 1 citra diprediksi sebagai red soil. Selanjutnya, ada 11 citra kategori red soil yang diprediksi salah, terdiri dari 9 citra diprediksi alluvial soil, 1 citra diprediksi black soil dan 1 citra lagi diprediksi sebagai clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 20 citra.



Gambar 4.5 Confusion Metrics Arsitektur VGG19

Untuk arsitektur VGG19 diperoleh bahwa dengan menggunakan kelima dataset yang ada, performa klasifikasi akurasi yang didapatkan adalah sama.

#### 4.2.4. Hasil Evaluasi pada Arsitektur DenseNet201

Pada Tabel 4.8 berikut menunjukkan performance metrics menggunakan arsitektur DenseNet201 pada setiap latent space dimension yang digunakan.

Tabel 4. 8 Performance Metrics Arsitektur DenseNet201

Metrics (%)	Latent space dimensi dim(z)				
	64	100	128	256	512
Accuracy	96	98	98	97	97
Precision	96	98	98	97	98
Recall	96	98	98	97	97
F1-Score	96	98	98	97	98

Dari tabel 4.8 diatas, dapat disimpulkan bahwa nilai performa metrics terbaik didapatkan pada penggunaan latent space dimensi 100 dan 128. Nilai akurasi, precision, recall dan F1-Score yang didapatkan pada penggunaan latent space dimension 100 dan 128 sama, yaitu 98%. Selanjutnya, performa terbaik kedua didapatkan pada penggunaan latent space dimension 512 dengan perolehan akurasi sebesar 97%, precision 98%, recall 97% dan F1-Score 98%. Performa terbaik berikutnya didapatkan pada penggunaan latent space dimension 256. Nilai pada performa metrics yang didapatkan semuanya sama, yaitu 97%. Dan performa terbaik akhir dengan nilai akurasi sebesar 96%, didapatkan pada penggunaan latent space dimension bernilai 64. Untuk nilai precision, recall dan F1-Score pada latent space dimension bernilai 64, juga sama yaitu, 96%.

Selanjutnya hasil confusion matrix pada arsitektur DensetNet201 untuk tiap dataset dengan latent space dimensi bernilai 64 ,100 ,128 ,256, dan 512 dapat dilihat pada Gambar 4.6 (a), (b), (c), (d) dan (e). Pada gambar 4.6 (a) hasil

confusion matrix menggunakan dataset latent space dimension 64, didapatkan sebanyak 4 citra kategori alluvial yang diprediksi salah sebagai black soil. Kemudian 5 citra kategori black soil diprediksi salah, terdiri dari 4 citra diprediksi alluvial soil dan 1 citra diprediksi red soil. Kemudian ada 3 citra kategori clay soil diprediksi salah, terdiri dari 2 citra diprediksi alluvial soil dan 1 citra diprediksi red soil. Dan terakhir ada 5 citra red soil yang diprediksi salah dimana 2 citra diprediksi sebagai alluvial soil dan 3 citra diprediksi sebagai black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 17 citra.

Selanjutnya untuk Gambar 4.6 (b) hasil confusion matrix menggunakan dataset latent space dimension 100. Diperoleh sebanyak 1 citra kategori alluvial yang diprediksi salah sebagai red soil. Selanjutnya 2 citra kategori black soil diprediksi salah sebagai alluvial soil. Lalu 2 citra clay soil diprediksi salah, masing-masing 1 citra diprediksi sebagai alluvial soil dan red soil. Dan selanjutnya, 4 citra kategori red soil yang diprediksi salah dimana, 1 citra diprediksi alluvial soil, dan sisanya 3 citra diprediksi black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 9 citra.

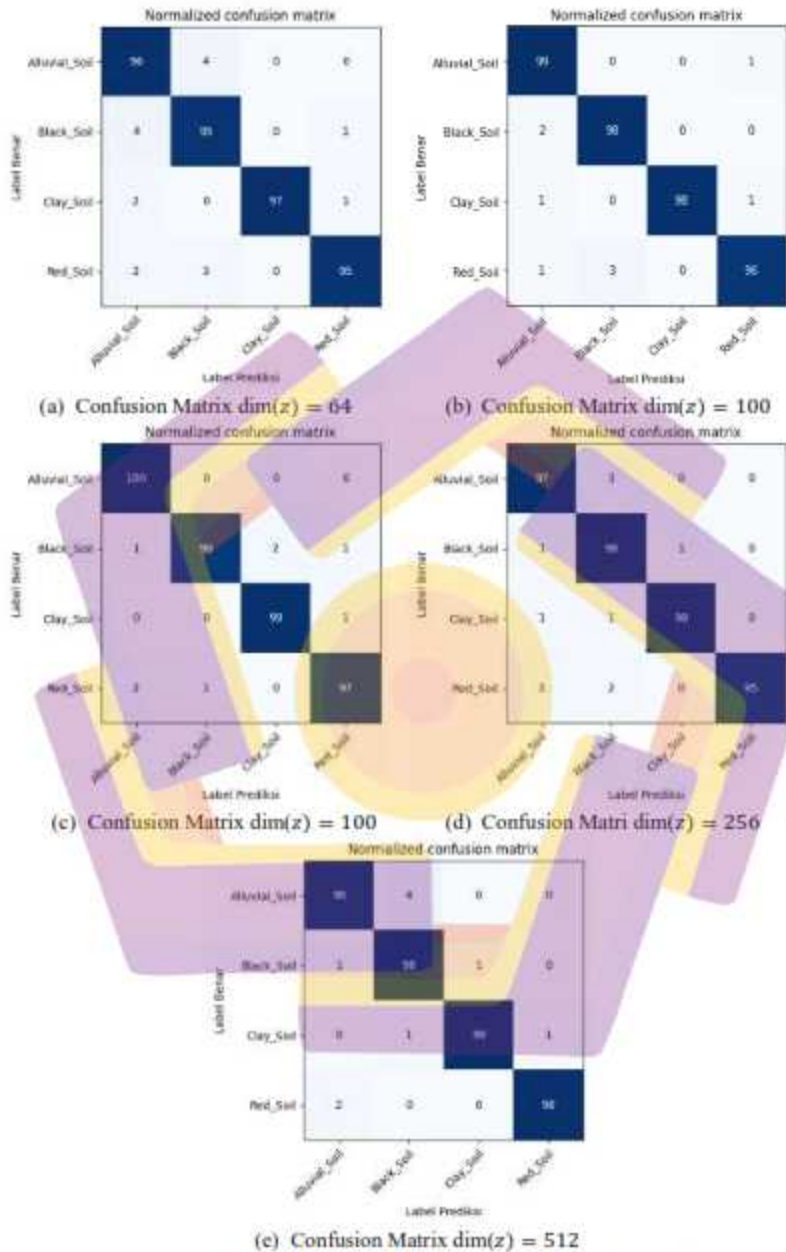
Untuk Gambar 4.6 (c) yang menggunakan dataset berlatent space dimension 128, diperoleh hasil confusion matrix yaitu 4 citra kategori black soil diprediksi salah yaitu citra diprediksi clay soil dan sisanya diprediksi sebagai alluvial soil dan red soil. Selanjutnya hanya 1 citra kategori clay soil yang diprediksi salah sebagai red soil. Dan terakhir, 3 citra kategori red soil yang diprediksi salah, terdiri dari 2 citra diprediksi sebagai alluvial soil dan 1 citra lagi diprediksi black



soil. Alluvial soil diprediksi benar semua. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 8 citra,

Berikutnya pada Gambar 4.6 (d) dimana hasil confusion matrix menggunakan dataset latent space dimension 256. Terdapat 3 citra kategori alluvial yang diprediksi salah sebagai kategori alluvial soil. Kemudian 2 citra kategori black soil diprediksi salah, masing-masing diprediksi kategori alluvial soil dan clay soil. Berikutnya ada 2 citra kategori clay soil yang diprediksi salah, masing-masing diprediksi alluvial soil dan black soil. Dan terakhir 5 citra kategori red soil yang diprediksi salah terdiri dari 3 citra diprediksi sebagai alluvial soil dan 3 citra lagi diprediksi sebagai black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 12 citra.

Dan terakhir untuk Gambar 4.6 (e) yang menggunakan dataset latent space dimension 512, diperoleh hasil confusion matrix yaitu sebanyak 4 citra kategori alluvial yang diprediksi salah sebagai black soil, Kemudian 2 citra pada kategori black soil diprediksi salah sebagai alluvial soil dan clay soil. Berikutnya sebanyak 2 citra kategori clay soil yang diprediksi sebagai black soil dan red soil. Dan terakhir red soil yang diprediksi salah sebanyak 2 citra juga sebagai citra kategori alluvial soil. Total keseluruhan citra yang diprediksi dengan salah adalah 10 citra



Gambar 4. 6 Confusion Metrics Arsitektur DenseNet201

Jadi, dari bagan confusion matrix diatas, disimpulkan bahwa Arsitektur DenseNet201 memiliki performa klasifikasi terbaik saat menggunakan dataset 100 dan dataset 128.

#### 4.2.5. Hasil Evaluasi pada Arsitektur InceptionResNetV2

Pada Tabel 4.9 berikut menunjukkan performance metrics menggunakan arsitektur DenseNet201 pada setiap latency space dimension yang digunakan.

Tabel 4.9 Performance Metrics Arsitektur InceptionResNetV2

Metrics (%)	Latent space dimensi dim (z)				
	64	100	128	256	512
Accuracy	93	95	95	91	93
Precision	93	95	95	91	93
Recall	93	95	95	91	93
F1-Score	93	95	95	91	93

Berdasarkan tabel diatas, performa metrics terbaik pertama dengan nilai akurasi 95%, nilai precision 95%, recall 95% dan F1-Score 95% didapatkan dengan menggunakan latent space dimension 100 dan 128. Selanjutnya, untuk performa metrics terbaik kedua, dengan nilai akurasi, nilai precision, nilai recall dan nilai f1-score sama, yaitu 93%, diperoleh dengan menggunakan latent space dimension bernilai 64 dan 512. Dan terakhir performa metrics rendah sebesar 91% didapatkan pada penggunaan latent space dimension berniali 256.

Selanjutnya hasil confusion matrix pada arsitektur InceptionResNetV2 untuk tiap dataset dengan latent space dimensi bernilai 64 ,100 ,128 ,256, dan 512 dapat dilihat pada Gambar 4.7 (a), (b), (c), (d) dan (e). Pada gambar 4.7 (a) hasil confusion matrix menggunakan dataset latent space dimension 64, diperoleh sebanyak 9 citra kategori alluvial yang diprediksi salah, terdiri atas 4 citra diprediksi black soil dan 5 citra red soil. Berikutnya terdapat 7 citra kategori black

soil diprediksi salah terdiri atas 2 citra diprediksi kategori alluvial soil. Selanjutnya ada 4 citra kategori clay soil yang diprediksi salah menjadi kategori alluvial soil. Dan ada 8 citra red soil yang diprediksi salah yaitu 7 citra diprediksi sebagai alluvial soil dan sisanya diprediksi clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 28 citra.

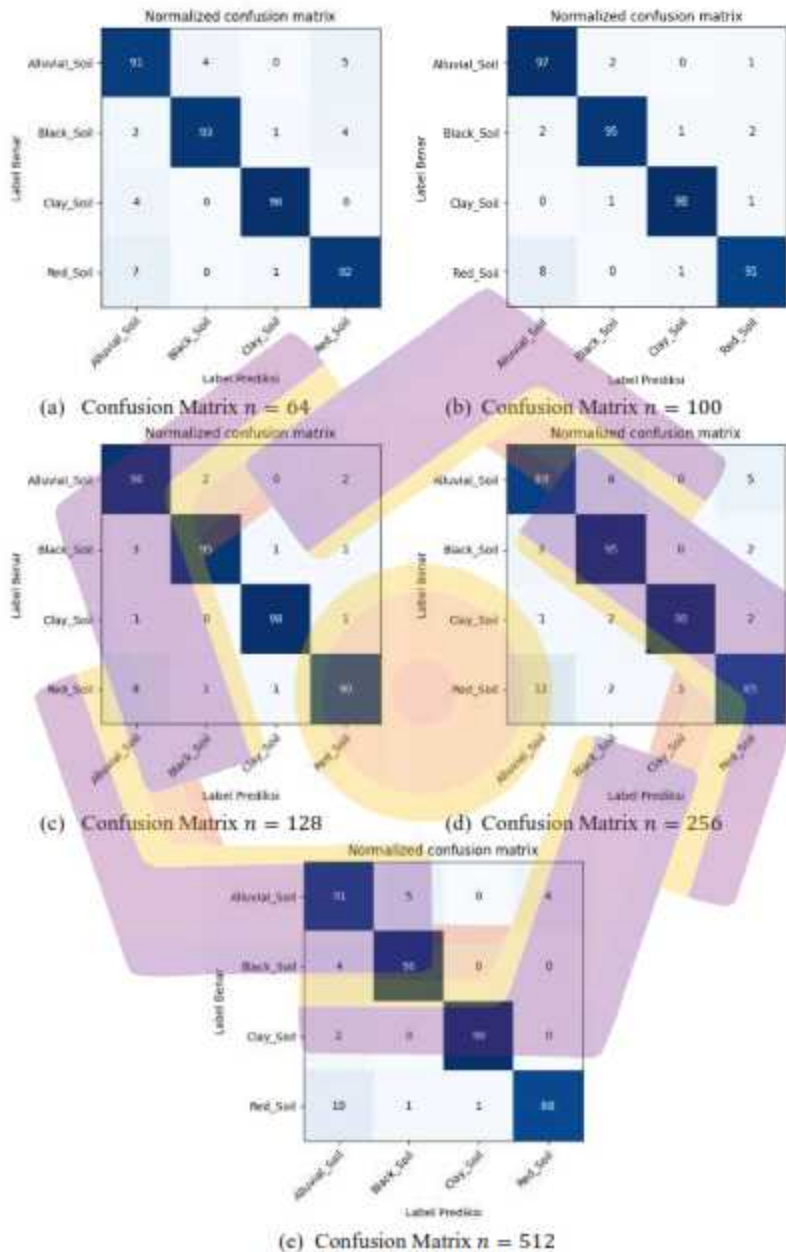
Selanjutnya untuk Gambar 4.7 (b) hasil confusion matrix menggunakan dataset latent space dimension 100. Diperoleh sebanyak 3 citra kategori alluvial yang diprediksi salah dimana 2 citra diprediksi sebagai kategori black soil dan satu citra diprediksi sebagai red soil. Selain itu, terdapat 5 citra kategori black soil diprediksi salah dimana sebanyak 2 citra diprediksi alluvial dan red soil, sisanya diprediksi clay soil. Lalu ada 2 citra clay soil yang diprediksi salah sebagai black soil dan red soil. Dan yang terakhir ada 9 citra kategori red soil yang diprediksi salah, terdiri atas 8 citra diprediksi kategori alluvial soil dan sisanya diprediksi sebagai clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 19 citra.

Untuk Gambar 4.7 (c) yang menggunakan dataset latent space dimension 128, diperoleh hasil confusion matrix yaitu 4 citra kategori alluvial diprediksi salah, masing-masing 2 citra dikategorikan sebagai black soil dan red soil. Kemudian ada 5 citra kategori black soil yang diprediksi salah terdiri dari 3 citra diprediksi alluvial soil dan sisanya diprediksikan sebagai clay soil dan red soil. Ada 2 citra kategori clay soil yang diprediksi salah, masing-masing diprediksikan berkategori alluvial dan red soil. Terakhir terdapat 10 citra kategori red soil yang kemudian diprediksi sebagai alluvial soil sebagai 8 citra dan sisanya masing-masing

diprediksi sebagai black soil dan clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 21 citra,

Berikutnya pada Gambar 4.7 (d) dimana hasil confusion matrix menggunakan dataset latent space dimension 256. Terdapat 11 citra kategori alluvial yang diprediksi salah, terdiri dari 6 citra dikategorikan black soil dan 5 citra dikategorikan red soil. Berikutnya ada 5 citra kategori black soil diprediksi salah yaitu 2 citra diprediksi sebagai alluvial soil dan 2 citra diprediksi sebagai red soil. Berikutnya ada 5 citra kategori clay soil diprediksi salah sebagai black soil dan red soil masing-masing sebanyak 2 citra dan 1 citra diprediksi sebagai alluvial soil. Dan terakhir terdapat 15 citra kategori red soil yang diprediksi salah sebagai alluvial soil sebanyak 12 citra, 2 citra diprediksi sebagai black soil dan sisanya diprediksi clay soil. Jadi total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 36 citra.

Dan terakhir untuk Gambar 4.7 (e) yang menggunakan dataset latent space dimension 512, diperoleh hasil confusion matrix yaitu sebanyak 9 citra kategori alluvial yang diprediksi salah dengan 5 citra diprediksi sebagai black soil dan 4 citra dikategorikan red soil. Lalu ada 4 citra pada kategori black soil yang diprediksi salah sebagai alluvial soil. Kemudian ada 2 citra clay soil diprediksi salah sebagai alluvial soil. Dan terakhir ada 12 citra red soil diprediksi salah sebagai alluvial soil sebanyak 10 citra dan sisanya masing-masing diprediksi clay soil dan black soil. Total keseluruhan citra yang diprediksi dengan salah adalah 27 citra



Gambar 4. 7 Confusion Metrics Arsitektur InceptionResNetV2

Jika dilihat melihat Gambar 4.7 confusion matrix serta Tabel 4.9 diatas, diperoleh bahwa Arsitektur InceptionResNetV2 memiliki performa klasifikasi terbaik saat menggunakan dataset 100 dan dataset 128, sama seperti arsitektur DenseNet201

#### 4.2.6. Hasil Evaluasi pada arsitektur Xception

Pada Tabel 4.10 berikut menunjukkan performance metrics menggunakan arsitektur Xception pada setiap latency space dimension yang digunakan.

Tabel 4. 10 Performance Metrics Arsitektur Xception

Metrics (%)	Latent space dimensi dim(z)				
	64	100	128	256	512
Accuracy	96	96	95	96	94
Precision	96	96	95	96	94
Recall	96	96	95	96	94
F1-Score	96	96	95	96	94

Berdasarkan tabel diatas, performa metrics terbaik pertama dengan nilai akurasi 96%, nilai precision 96%, recall 96% dan F1-Score 96% didapatkan dengan menggunakan latent space dimension 64,100 dan 256. Selanjutnya, untuk performa metrics terbaik kedua, dengan nilai akurasi, nilai precision, nilai recall dan nilai f1-score sama, yaitu 95%, diperoleh dengan menggunakan latent space dimension bernilai 128. Dan terakhir performa metrics rendah sebesar 94% didapatkan pada penggunaan latent space dimension bernilia 512.

Kemudian hasil confusion matrix pada arsitektur Xception untuk tiap dataset dengan latent space dimensi bernilai 64 ,100 ,128 ,256, dan 512 dapat dilihat pada Gambar 4.8 (a), (b), (c), (d) dan (e). Pada gambar 4.8 (a) hasil confusion matrix menggunakan dataset latent space dimension 64, didapatkan sebanyak 6 citra kategori alluvial yang diprediksi salah sebagai black soil dan red

soil, masing-masing sebanyak 3 citra. Kemudian ada 4 citra kategori black soil diprediksi salah yang terdiri dari 2 citra dikategorikan clay soil, 1 citra dikategorikan alluvial soil dan satunya lagi dikategorikan red soil. Berikutnya terdapat 5 citra kategori red soil yang diprediksi salah terdiri atas 4 citra diprediksi alluvial dan sisanya dikategorikan black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 15 citra.

Selanjutnya untuk Gambar 4.8 (b) hasil confusion matrix menggunakan dataset latent space dimension 100. Diperoleh sebanyak 4 citra kategori alluvial yang diprediksi salah sebagai black soil 2 citra dan red soil sebanyak 2 citra. Berikutnya ada 6 citra kategori black soil diprediksi salah masing-masing sebanyak 2 citra diprediksi sebagai alluvial, clay dan red soil. Terdapat 1 citra clay soil yang diprediksi salah sebagai red soil. Dan ada 6 citra kategori red soil yang diprediksi salah sebagai alluvial soil sebanyak 3 citra, 2 citra sebagai black soil dan sisanya sebagai clay soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 17 citra.

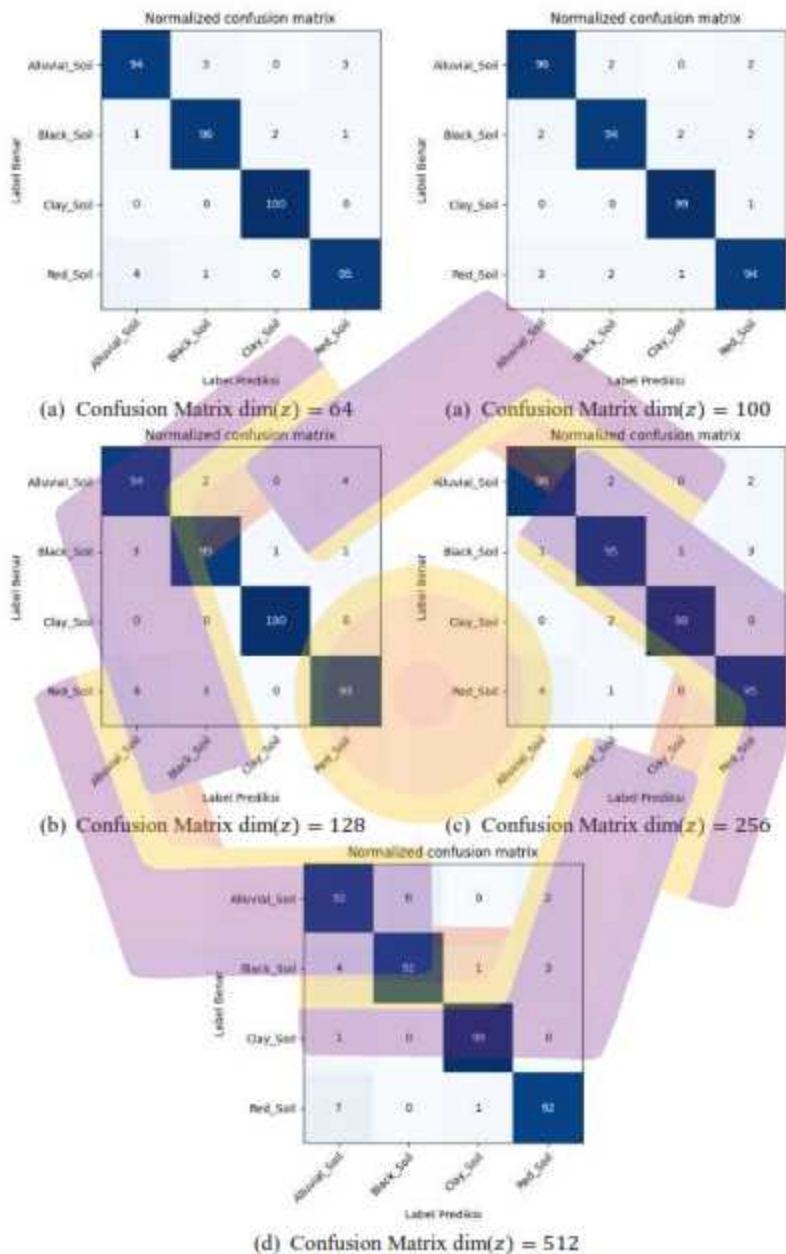
Untuk Gambar 4.8 (c) yang menggunakan dataset latent space dimension 128, diperoleh hasil confusion matrix yaitu 6 citra kategori alluvial diprediksi salah terdiri atas 2 citra diprediksi sebagai black soil dan 4 citra diprediksi sebagai red soil. Lalu ada 4 citra kategori black soil yang diprediksi salah sebagai alluvial soil sebanyak 3 citra dan sisanya masing-masing clay soil dan red soil. Ada 7 citra kategori red soil yang diprediksi salah terdiri dari 4 empat citra diprediksi sebagai alluvial soil dan 3 citra diprediksi sebagai black soil. Alluvial soil diprediksi benar



semua. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 18 citra,

Berikutnya pada Gambar 4.8 (d) dimana hasil confusion matrix menggunakan dataset latent space dimension 256. Terdapat 4 citra kategori alluvial yang diprediksi salah terdiri dari 2 citra diprediksi sebagai black soil dan 2 citra diprediksi sebagai red soil. Kemudian ada 4 citra kategori red soil yang diprediksi salah dengan kategori red soil sebanyak 3 citra, 1 citra diprediksi sebagai clay soil dan 1 lagi diprediksi sebagai alluvial soil. Kemudian ada 2 citra kategori clay soil diprediksi salah sebagai black soil. Dan terakhir ada 5 citra kategori red soil yang diprediksi salah terdiri dari 4 citra dikategorikan alluvial soil dan 1 citra dikategorikan black soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 16 citra.

Dan terakhir untuk Gambar 4.8 (e) yang menggunakan dataset latent space dimension 512, diperoleh hasil confusion matrix yaitu sebanyak 8 citra kategori alluvial yang diprediksi salah terdiri dari 6 citra dikategorikan black soil dan 2 citra dikategorikan red soil. Kemudian ada 8 citra pada kategori black soil yang diprediksi salah dimana 4 citra diprediksi sebagai alluvial soil, 1 citra diprediksi sebagai clay soil dan 3 citra red soil. Lalu hanya ada 1 citra clay soil diprediksi salah sebagai alluvial soil. Dan kemudian ada 8 citra red soil diprediksi salah terdiri dari 7 citra diprediksi sebagai alluvial soil dan 1 citra diprediksi sebagai clay soil. Total keseluruhan citra yang diprediksi dengan salah adalah 26 citra




Gambar 4. 8 Confusion Metrics Arsitektur Xception

Dari Gambar 4.8 confusion matrix serta Tabel 4.10 performance matrix untuk arsitektur Xception diatas, diperoleh bahwa arsitektur tersebut dapat memiliki performa klasifikasi terbaik saat menggunakan dataset 64, dataset 100, dan dataset 256.

#### 4.2.7. Hasil Evaluasi pada arsitektur CNN

Selanjutnya, selain menggunakan keenam arsitektur CNN diatas, peneliti juga mencoba menggunakan membangun arsitektur CNN. Berikut Gambar 4.9 adalah arsitektur CNN



Gambar 4. 9 Arsitektur CNN yang diajukan.

Inputan gambar yang digunakan pada model CNN diatas adalah  $224 \times 224 \times 3$ . Model terdiri atas *Layer Convolutional*, *Layer Maxpooling*, serta *Layer BatchNormalization*. Dari Gambar 4.9 diatas, diketahui bahwa *Layer Convolutional* sebanyak 5 (lima) layer. dengan fungsi aktivasi yang digunakan adalah ReLU (*Rectified Linear Unit*). Dimana setiap layer *convolution* ditambahkan *layer maxpooling* dan *layer batchnormalization*. Untuk layer output klasifikasi atau *Fully connection* terdiri atas *Layer Dropout*, *layer Flatten* dan *layer Dense* dengan fungsi aktivasi yang digunakan adalah softmax. Optimazer

yang digunakan dalam melakukan training adalah *Adamax optimizer* dengan *learning\_rate* = 0.001. Penggunaan *Batch Size* pada proses training yaitu 32 dengan epoch sebanyak 50. Setelah proses training, selanjutnya peneliti melakukan proses evaluasi model dan mengukurnya performa model menggunakan performance yang hasilnya dapat dilihat pada Tabel 4.11 Hasil performance metrics menggunakan arsitektur CNN.

Tabel 4. 11 Performance Metrics Arsitektur CNN

Metrics (%)	Latent space dimensi $\dim(z)$				
	64	100	128	256	512
Accuracy	97	99	98	97	98
Precision	97	99	98	97	98
Recall	97	99	98	97	98
F1-Score	97	99	98	97	98

Berdasarkan tabel diatas, performa metrics terbaik pertama dengan nilai akurasi 99%, nilai precision 99%, recall 99% dan F1-Score 99% didapatkan dengan menggunakan latent space dimension bernilai 100. Selanjutnya, untuk performa metrics terbaik kedua, dengan nilai akurasi, nilai precision, nilai recall dan nilai f1-score sama, yaitu 98%, diperoleh dengan menggunakan latent space dimension bernilai 128 dan 512. Dan terakhir performa metrics rendah sebesar 97% didapatkan pada penggunaan latent space dimension bernilia 64 dan 256.

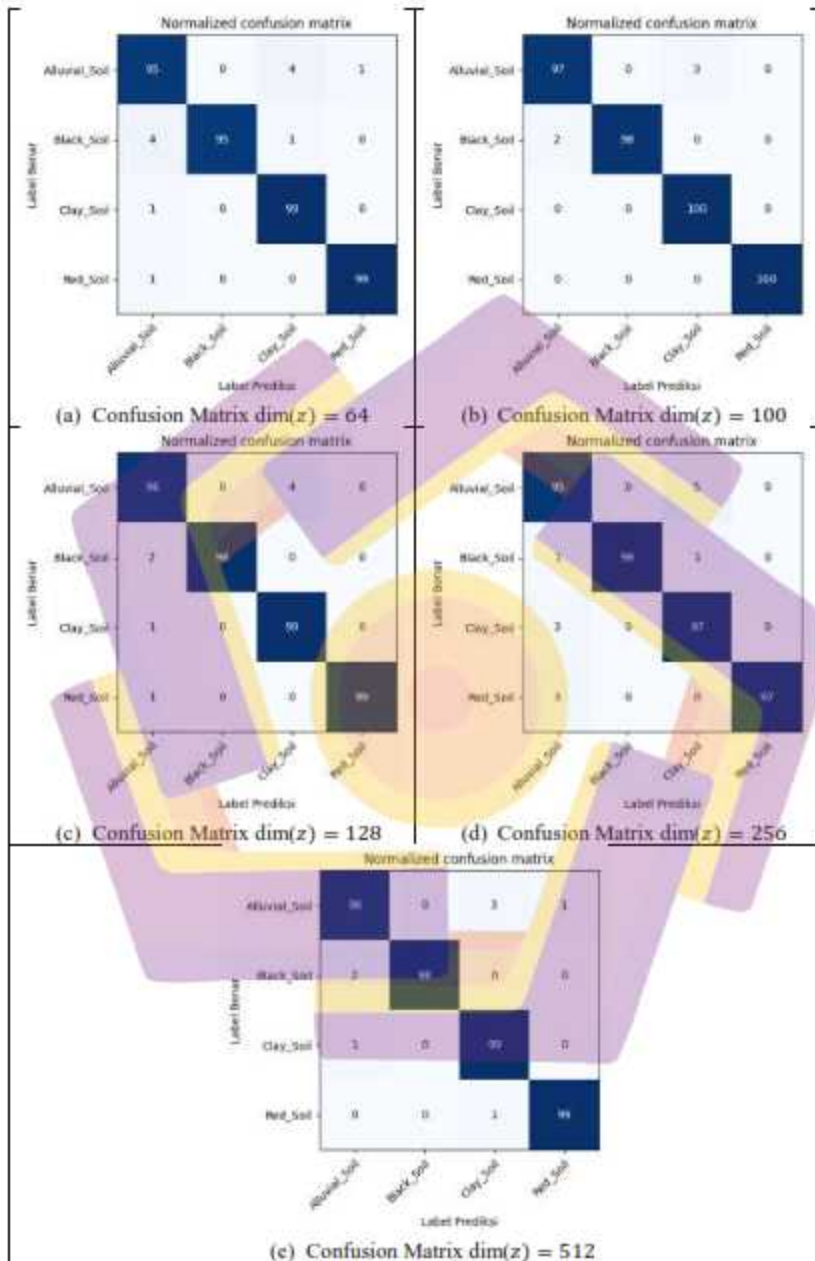
Kemudian hasil confusion matrix pada arsitektur CNN untuk tiap dataset dengan latent space dimensi bernilai 64 ,100 ,128 ,256, dan 512 dapat dilihat pada Gambar 4.9 (a), (b), (c), (d) dan (e). Pada gambar 4.9 (a) hasil confusion matrix menggunakan dataset latent space dimension 64, didapatkan sebanyak 5 citra kategori alluvial yang diprediksi salah, terdiri dari 5 citra dikategorikan black soil dan 1 citra dikategorikan red soil. Kemudian ada 5 citra juga kategori black soil

yang diprediksi salah, terdiri dari 1 citra dikategorikan clay soil, dan 4 citra dikategorikan alluvial soil. Berikutnya terdapat 1 citra kategori clay soil yang diprediksi salah sebagai alluvial soil. Dan hanya 1 citra kategori red soil yang juga diprediksi salah sebagai alluvial soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 12 citra.

Selanjutnya untuk Gambar 4.9 (b) hasil confusion matrix menggunakan dataset latent space dimension 100. Diperoleh sebanyak 3 citra kategori alluvial yang diprediksi salah sebagai clay soil. Berikutnya ada 2 citra kategori black soil diprediksi salah sebagai alluvial soil. Total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 5 citra lebih sedikit dari total kesalahan sebelumnya.

Untuk Gambar 4.9 (c) yang menggunakan dataset latent space dimension 128, diperoleh hasil confusion matrix yaitu 4 citra kategori alluvial diprediksi salah sebagai clay soil. Lalu ada 2 citra kategori black soil yang diprediksi salah sebagai alluvial soil. Terdapat 1 citra pada kategori clay soil dan red soil yang diprediksi salah sebagai alluvial soil. Untuk total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 8 citra,

Berikutnya pada Gambar 4.9 (d) dimana hasil confusion matrix menggunakan dataset latent space dimension 256. Terdapat 5 citra kategori alluvial yang diprediksi salah sebagai clay soil. Kemudian ada 2 citra kategori black soil yang diprediksi salah yaitu 1 citra diprediksi alluvial soil dan 1 citra lagi diprediksi

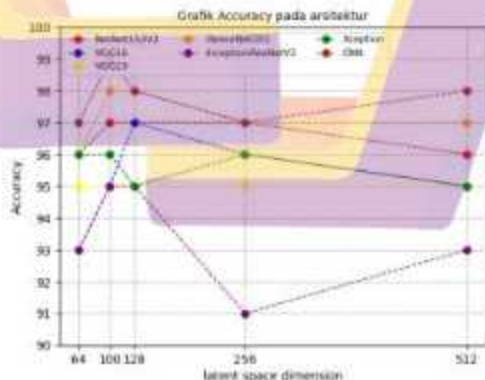


Gambar 4. 10 Confusion Metrics Arsitektur CNN

sebagai clay soil. Selanjutnya terdapat 3 citra pada red soil dan clay soil, yang masing-masing diprediksi sebagai alluvial soil. Jadi total keseluruhan citra yang diprediksi salah tidak sesuai dengan labelnya adalah 13 citra.

Dan terakhir untuk Gambar 4.9 (e) yang menggunakan dataset latent space dimension 512, diperoleh hasil confusion matrix yaitu sebanyak 4 citra kategori alluvial yang diprediksi salah terdiri dari 3 citra dikategorikan sebagai clay soil dan 1 citra dikategorikan red soil. Kemudian ada 2 citra pada kategori black soil yang diprediksi salah sebagai alluvial soil. Lalu hanya ada 1 citra clay soil yang diprediksi salah sebagai alluvial soil. Serta terdapat 1 citra red soil yang juga diprediksi salah sebagai clay soil. Sehingga total keseluruhan citra yang diprediksi dengan salah adalah 8 citra.

Dari Tabel 4.11 dan Gambar 4.10 berkaitan dengan hasil performa model CNN yang dibuat, diperoleh performa klasifikasi terbaik dengan menggunakan dataset 100. Berikut adalah Gambar 4.11 Grafik akurasi yang diperoleh pada setiap arsitektur yang diujicoba pada penelitian ini.



Gambar 4. 11 Grafik akurasi pada setia Arsitektur

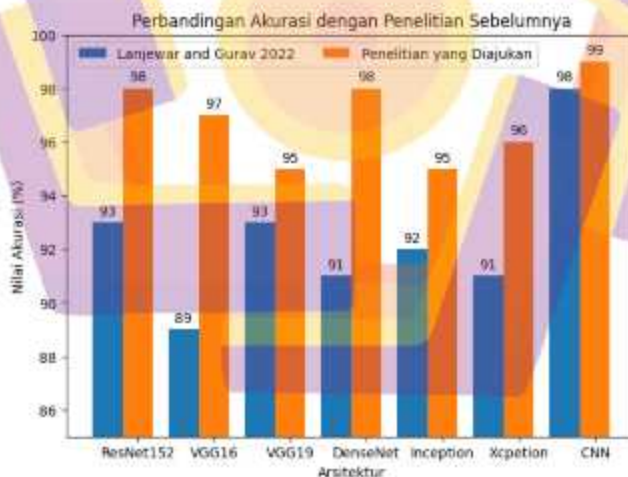
Berdasarkan gambar grafik diatas, untuk arsitektur ResNet152V2 akurasi tertinggi diperoleh sebesar 97% dengan latent space dimension yang digunakan pada citra sebesar 100 dan 128. Selanjutnya, untuk arsitektur VGG16, akurasi tertinggi didapat sebesar 97% juga yang menggunakan latent space dimension 128 pada citra. Untuk arsitektur VGG19 nilai akurasi semua sama pada setiap latent space dimension yaitu 95%. Kemudian untuk DenseNet, nilai akurasi tertinggi sebesar 98% yang didapatkan pada penggunaan latent space dimension 100 dan 128 juga. Selanjutnya pada arsitektur InceptionResNetV2 didapatkan nilai akurasi tertinggi sebesar 95% dengan menggunakan latent space dimension yang sama dengan arsitektur sebelumnya yaitu 100 dan 128. Untuk arsitektur Xception yang memiliki akurasi tertinggi sebesar 96% didapatkan dengan menggunakan latent space dimension 64, 100 dan 256. Dan terakhir dari arsitektur CNN, didapatkan akurasi tertinggi sebesar 98% dengan menggunakan dataset latent space dimension 100, 128 dan 512. Dari ketujuh arsitektur yang disebutkan diatas, nilai akurasi tertinggi yaitu 98% diperoleh dengan menggunakan arsitektur DenseNet201 dan CNN pada latent space dimension 100, 128 dan 512. Selain itu bila dilihat dari gambar Grafik 4.10 diatas, nilai akurasi terbaik selalu didapatkan dengan menggunakan latent space dimension 100 dan 128. Hal ini dapat disimpulkan bahwa penggunaan latent space dimension yang dapat menghasilkan akurasi terbaik yaitu bernilai 100 dan selanjutnya adalah 128.

#### **4.2.8. Perbandingan dan penelitian sebelumnya**

Selanjutnya, peneliti melakukan perbandingan penelitian dengan penelitian sebelumnya (Lanjewar and Gurav 2022). Pada penelitian ini, jenis arsitektur



DCCN yang digunakan untuk proses klasifikasi gambar adalah sama dengan penelitian yang dibandingkan. Melalui perbandingan ini, peneliti ingin melihat perubahan terhadap akurasi yang dihasilkan dengan menggunakan data augmentasi. Nilai akurasi yang digunakan peneliti adalah nilai akurasi tertinggi, yang diperoleh dengan menggunakan latent space dimension 100. Berikut Gambar 4.11 terkait gambar grafik yang menampilkan hasil akurasi yang didapatkan pada penelitian sebelumnya dengan hasil akurasi yang didapatkan pada penelitian yang diajukan. Dari gambar grafik tersebut terlihat bahwa penelitian yang diusulkan memiliki hasil akurasi yang lebih tinggi. Pada arsitektur ResNet152V, terjadi peningkatan sebesar 5% dari angka 93% menjadi 98%. Kemudian untuk arsitektur VGG16, terjadi peningkatan sebesar 8% dari angka 89% menjadi 97%. Untuk lebih jelasnya perhatikan Gambar 4.11 berikut



Gambar 4. 12 Grafik Perbandingan Akurasi dengan Penelitian Sebelumnya

Lalu, untuk arsitektur VGG19, terjadi peningkatan akurasi sebesar 2% dari angka 93% menjadi 95%. Pada arsitektur DenseNet201, peningkatan arsitektur sebesar 7% dari angka 91% menjadi 98%. Selanjutnya pada arsitektur InceptionResnetV2, terjadi peningkatan sebesar 3% dari angka 92% menjadi 95%. Pada arsitektur Xception, peningkatan akurasi terjadi sebesar 5%, mulai dari angka 91% menjadi 95%. Untuk arsitektur CNN yang digunakan tidak terjadi peningkatan. Nilai akurasi yang diperoleh sama dengan penelitian sebelumnya. Namun terdapat perbedaan pada nilai precision dan F1-Score yang diperoleh. Pada penelitian sebelumnya, nilai precision dan F1-Score yang diperoleh sebesar 98%. Sedangkan pada penelitian yang diajukan, nilai precision dan F1-Score yang didapatkan berdasarkan Tabel 4.11 diatas yaitu 99%.

Dari ketujuh arsitektur yang digunakan diatas, peningkatan akurasi terbesar terjadi pada arsitektur VGG16 disusul arsitektur DenseNet201. Ini mengartikan bahwa terdapat peningkatan akurasi yang dihasilkan pada arsitektur CNN dengan menggunakan citra sintesis yang dibuat melalui model DCGAN.

Kemudian peneliti mencoba mengukur akurasi dengan menggunakan arsitektur CNN yang digunakan oleh (Lanjewar and Gurav 2022) terhadap dataset sintesis yang telah dibuat oleh peneliti. Dan juga, peneliti mencoba menggunakan arsitektur CNN yang telah dibuat terhadap dataset awal yang digunakan oleh (Lanjewar and Gurav 2022). Untuk hasil akurasi yang diperoleh dapat dilihat pada Tabel dibawah ini 4.12 berikut ini.

Tabel 4. 12 Perbandingan Akurasi Terhadap Dataset

Model	Accuracy
Arsitektur CNN (c + Dataset Sintesis)	98%
Arsitektur CNN (Peneliti yang diusulkan) + Dataset non sintesis	98%
Arsitektur CNN (Peneliti yang diusulkan) + Dataset Sintesis	99%

Dari tabel diatas, dapat ditarik kesimpulan bahwa, dataset sintesis yang digunakan untuk menyeimbangkan kategori pada dataset (Lanjewar and Gurav 2022), ternyata dapat meningkatkan performa hasil akurasi untuk klasifikasi jenis tanah.

Tabel 4. 13 Perbandingan Akurasi dengan Penelitian Sebelumnya

Peneliti	Metode	Hasil (%)			Dataset
		Precision	Accuracy	F1-Score	
(Bhattacharya and Solomatine 2006)	Decision Trees, ANN, and SVM		89.34, 87, dan 71.18		(Bhattacharya and Solomatine 2006)
(Azizi et al. 2020)	ResNet50	98.08	98.72	100	(Azizi et al. 2020)
(Ronaldo 2021)	CNN	97	97	97	(Ronaldo 2021)
(Chatterjee et al. 2021)	ResNet50		Training accuracy – 99.4		(Chatterjee et al. 2021)
(Lanjewar and Gurav 2022)	CNN	98	98	98	(Lanjewar and Gurav 2022)
<b>Penelitian yang diusulkan</b>	<b>CNN</b>	<b>99</b>	<b>99</b>	<b>99</b>	(Lanjewar and Gurav 2022)

Selanjutnya peneliti juga mencoba melakukan perbandingan hasil dengan penelitian sebelumnya dengan menggunakan metode klasifikasi yang berbeda serta hasil dan dataset yang berbeda pula. Hasilnya dapat dilihat pada Tabel 4.12 terkait perbandingan akurasi dengan penelitian sebelumnya. Pada tabel 4.12 tersebut, bisa dilihat bahwa hasil akurasi terbaik didapatkan pada penelitian yang

diusulkan dengan menggunakan arsitektur CNN. Nilai akurasi, precision dan F1-Score yang didapatkan sebesar 99%.

Dari tabel 4.13 diatas, dapat disimpulkan bahwa performa akurasi yang didapatkan dengan menggunakan dataset hasil augmentasi model DCGAN masih terlihat bagus. Hal ini dibuktikan dengan adanya peningkatan akurasi terhadap proses klasifikasi gambar dengan menggunakan model CNN.



## **BAB V**

### **PENUTUP**

#### **5.1. Kesimpulan**

Dari hasil penelitian yang dilakukan maka dapat disimpulkan bahwa nilai parameter latency dimension memiliki pengaruh terhadap hasil citra yang dibuat oleh model DCGAN. Nilai parameter latent dimension terbaik yang digunakan adalah  $\dim(z)=100$  dengan score FID yang didapatkan sebesar 267,39. Score FID tersebut adalah score FID terkecil bila dibandingkan dengan score FID lainnya yang didapatkan dengan menggunakan nilai parameter latency 64, 128, 256 dan 512. Kemudian, dalam klasifikasi tanah menggunakan citra sintesis hasil augmentasi tersebut, diperoleh adanya peningkatan akurasi yang terjadi pada semua arsitektur yang diuji coba. Peningkatan akurasi tertinggi didapatkan pada arsitektur VGG16, dengan peningkatan sebesar 8%. Dan dari keenam pengembangan arsitektur CNN serta arsitektur CNN yang dibangun sendiri, nilai akurasi tertinggi didapatkan sebesar 99% menggunakan arsitektur CNN yang dibangun sendiri.

Dengan adanya penelitian ini, diharapkan dapat membantu dalam menghasilkan citra tanah sintesis yang baik untuk menangani masalah imbalanced kategori yang terjadi pada dataset tanah serta menangani masalah sulitnya atau kekurangan dataset.

## 5.2. Saran

Perlu adanya penelitian lebih lanjut ataupun pengembangan penelitian yang berkaitan tentang penilaian kualitas citra menggunakan FID Score dengan menggunakan dataset yang sama. Untuk output gambarnya dihasilkan pada penelitian ini adalah 128x128x3. Baiknya perlu dilakukan pengembangan juga terkait efek *latent space dimension* terhadap ukuran gambar yang dihasilkan.

Kemudian perlu juga adanya pengembangan terkait arsitektur model DCGAN serta parameter-parameter yang berpengaruh terhadap kualitas citra yang dihasilkan oleh model DCGAN.



## DAFTAR PUSTAKA

- Adhinata, Faisal Dharma, Diovianto Putra Rakhmadani, Merlinda Wibowo, and Akhmad Jayadi. 2021. "A Deep Learning Using DenseNet201 to Detect Masked or Non-Masked Face." *JUITA: Jurnal Informatika* 9(1): 115.
- Andrew, Andrew, and Handri Santoso. 2022. "Compare VGG19, ResNet50, Inception-V3 for Review Food Rating." *Sinkron* 7(2): 845–494.
- Ayan, Enes, Hasan Erbay, and Fatih Varçın. 2020. "Crop Pest Classification with a Genetic Algorithm-Based Weighted Ensemble of Deep Convolutional Neural Networks." *Computers and Electronics in Agriculture* 179(October): 105809. <https://doi.org/10.1016/j.compag.2020.105809>.
- Azizi, Afshin et al. 2020. "Classification of Soil Aggregates: A Novel Approach Based on Deep Learning." *Soil and Tillage Research* 199(March 2019).
- Barman, Utpal, and Ridip Dev Choudhury. 2020. "Soil Texture Classification Using Multi Class Support Vector Machine." *Information Processing in Agriculture* 7(2): 318–32.
- Bhattacharya, B., and D. P. Solomatine. 2006. "Machine Learning in Soil Classification." *Neural Networks* 19(2): 186–95.
- Borji, Ali. 2019. "Pros and Cons of GAN Evaluation Measures." *Computer Vision and Image Understanding* 179: 41–65.
- Brock, Andrew, Jeff Donahue, and Karen Simonyan. 2019. "Large Scale GAN Training for High Fidelity Natural Image Synthesis." *7th International Conference on Learning Representations, ICLR 2019*: 1–35.
- Chatterjee, Kajal et al. 2021. "Classification of Soil Images Using Convolution Neural Networks." In *2021 International Conference on Communications, Computing, Cybersecurity, and Informatics (CCCI)*, , 1–5.
- Creswell, Antonia et al. 2018. "Deep Learning for Visual Understanding: Part 2 Generative Adversarial Networks." *IEEE Signal Processing Magazine* (January): 53–65. <https://twinkl-hub.tw/6638/2bc534ddaf5c9240cff3e1bb1697682/creswell2018.pdf#page=1>

- Diantoro, Karno, and Budhy Adriansyah. 2019. "Sistem Identifikasi Jenis Burung Dengan Image Classification Menggunakan OpenCV." *Tekinfo* 20(1)(1): 96-105.
- Francois Chollet; Google, Inc. 2014. "Xception: Deep Learning with Depthwise Separable Convolutions." *SAE International Journal of Materials and Manufacturing* 7(3): 560-66.
- Frid-Adar, Maayan et al. 2018. "GAN-Based Synthetic Medical Image Augmentation for Increased CNN Performance in Liver Lesion Classification." <http://arxiv.org/abs/1803.01229>.
- Goodfellow, Ian et al. 2020. "Generative Adversarial Networks." *Communications of the ACM* 63(11): 139-44.
- He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. 2016. "Deep Residual Learning for Image Recognition." *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition 2016-Decem*: 770-78.
- Heusel, Martin et al. 2017. "GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium." *Advances in Neural Information Processing Systems 2017-Decem(Nips)*: 6627-38.
- Huang, Gao, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q. Weinberger. 2017. "Densely Connected Convolutional Networks." *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017 2017-Janua*: 2261-69.
- Hwang, K. M. Ngoc and M. 2020. "Finding the Best k for the Dimension of the Latent Space in Autoencoders." In *International Conference on Computational Collective Intelligence*, Springer, 453-64.
- Karras, Tero, Timo Aila, Samuli Laine, and Jaakko Lehtinen. 2018. "Progressive Growing of GANs for Improved Quality, Stability, and Variation." *6th International Conference on Learning Representations, ICLR 2018 - Conference Track Proceedings*: 1-26.



- Lanjewar, M G, and O L Gurav. 2022. "Convolutional Neural Networks Based Classifications of Soil Images." *Multimedia Tools and Applications* 81(7): 10313–36. <https://doi.org/10.1007/s11042-022-12200-y>.
- Leonardo, Matheus Macedo et al. 2019. "Deep Feature-Based Classifiers for Fruit Fly Identification (Diptera: Tephritidae)." *Proceedings - 31st Conference on Graphics, Patterns and Images, SIBGRAPI 2018* (May 2019): 41–47.
- Liu, Bingqi et al. 2022. "Application of an Improved DCGAN for Image Generation." *Mobile Information Systems* 2022.
- Liu, Ming Yu, and Oncel Tuzel. 2016. "UNROLLED GENERATIVE ADVERSARIAL NETWORKS." *Advances in Neural Information Processing Systems*: 469–77.
- Ma, Li et al. 2020. "Combining DC-GAN with ResNet for Blood Cell Image Classification." *Medical and Biological Engineering and Computing* 58(6): 1251–64.
- Marin, Ivana, Sven Gotovac, Mladen Russo, and Dunja Božić-Štulić. 2021. "The Effect of Latent Space Dimension on the Quality of Synthesized Human Face Images." *Journal of Communications Software and Systems* 17(2): 124–33.
- Mirza, Mehdi, and Simon Osindero. 2014. "Conditional Generative Adversarial Nets." : 1–7. <http://arxiv.org/abs/1411.1784>.
- Of, Mpac et al. 2020. "Impact of the Latent Space on the Ability of GANs to Fit the Distribution." (2014): 1–13.
- Pintelas, E.; Livieris, I.E.; Pintelas, P.E. 2021. "A Convolutional Autoencoder Topology for Classification in High-Dimensional Noisy Image Datasets." *Sensors*: 1–16.
- Prilianti, Kestriia Rega et al. 2020. "Real-Time Assessment of Plant Photosynthetic Pigment Contents with an Artificial Intelligence Approach in a Mobile Application Om m Er Ci Al Us e on l y m Al." LI.
- "Pytorch-Fid." 2023. <https://pypi.org/project/pytorch-fid/>.

- Radford, Alec, Luke Metz, and Soumith Chintala. 2016. "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks." *4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings*: 1–16.
- Robbani, Ihwanudien Hasan et al. 2016. "APLIKASI MOBILE SCOTECT : APLIKASI DETEKSI WARNA TANAH DENGAN." 3(1): 19–26.
- Ronaldo, Antony David. 2021. "Effective Soil Type Classification Using Convolutional Neural Network." *International Journal of Informatics and Computation* 3(1): 20.
- Sáez Trigueros, Daniel, Li Meng, and Margaret Hartnett. 2021. "Generating Photo-Realistic Training Data to Improve Face Recognition Accuracy." *Neural Networks* 134: 86–94. <https://doi.org/10.1016/j.neunet.2020.11.008>.
- Salimans, Tim et al. 2016. "Improved Techniques for Training GANs." *Advances in Neural Information Processing Systems*: 2234–42.
- Sandhopi, Lukman Zaman P.C.S.W, and Yosi Kristian. 2020. "Identifikasi Motif Jepara Pada Ukiran Dengan Memanfaatkan Convolutional Neural Network." *Jurnal Nasional Teknik Elektro dan Teknologi Informasi* 9(4): 403–13.
- Secada Purba, Eric. *IMPLEMENTATION OF GENERATIVE ADVERSARIAL NETWORKS FOR CREATING DIGITAL ARTWORK IN THE FORM OF ABSTRACT IMAGES*.
- Silva, Manuel F, José Luis, Luis Paulo, and Reis Alberto. 2019. 1 *Advances in Intelligent Systems and Computing 1092 Robot 2019: Fourth Iberian Robotics Conference*.
- Smaida, Mahmoud, Serhii Yaroshchak, and Youness El Barg. 2021. "DCGAN for Enhancing Eye Diseases Classification." *CEUR Workshop Proceedings* 2864: 22–33.
- Szegedy, Christian, Sergey Ioffe, Vincent Vanhoucke, and Alexander A. Alemi. 2017. "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning." *31st AAAI Conference on Artificial Intelligence, AAAI 2017*: 4278–84.

- Thakur, Ritula. 2018. "An Intelligent Model for Indian Soil Classification Using Various Machine Learning Techniques." (November): 33–41.
- Venu, Sagar Kora, and Sridhar Ravula. 2021. "Evaluation of Deep Convolutional Generative Adversarial Networks for Data Augmentation of Chest X-Ray Images." *Future Internet* 13(1): 1–13.
- Waheed, Abdul et al. 2020. "CovidGAN: Data Augmentation Using Auxiliary Classifier GAN for Improved Covid-19 Detection." *IEEE Access* 8: 91916–23.
- Wickramasinghe, Chathurika S., Daniel L. Marino, and Milos Manic. 2021. "ResNet Autoencoders for Unsupervised Feature Learning from High-Dimensional Data; Deep Models Resistant to Performance Degradation." *IEEE Access* 9: 40511–20.
- Winarto, Eveline Gabriela, Rahmayati, and Armin Lawi. 2021. "Implementasi Arsitektur Inception Resnet-V2 Untuk Klasifikasi Kualitas Biji Kakao." *Konferensi Nasional Ilmu Komputer (KONIK) 2021* : 132–37.
- Winkler, Stefan. 2018. "GENERATIVE ADVERSARIAL NETWORKS FOR IMAGE STEGANOGRAPHY." (2010): 1–12.
- Ying, Xue. 2019. "An Overview of Overfitting and Its Solutions." *Journal of Physics: Conference Series* 1168(2).
- Yuwana, R. Sandra et al. 2020. "Data Augmentation Using Adversarial Networks for Tea Diseases Detection." *Jurnal Elektronika dan Telekomunikasi* 20(1): 29.
- Zhang, Danlu, Jingguo Lv, and Zhe Cheng. 2020. "An Approach Focusing on the Convolutional Layer Characteristics of the VGG Network for Vehicle Tracking." *IEEE Access* 8: 112827–39.
- Zhu, Xinyue et al. 2018. "Emotion Classification with Data Augmentation Using Generative Adversarial Networks." *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10939 LNAI(November 2017): 349–60.