

**SEGMENTASI AKAR PADA CITRA TANAH DENGAN  
MENGIMPLEMENTASIKAN METODE *ENSEMBLE  
LEARNING* MENGGUNAKAN TEKNIK *WEIGHTED  
AVERAGE* PADA ARSITEKTUR *U-NET* DAN *DENSENET***

**SKRIPSI**

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
Sarjana Sains Bidang Studi Matematika**

**Oleh:**

**ANISA AULIA KUSMARENI**

**NIM 08011281823031**



**JURUSAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS SRIWIJAYA**

**2022**

**HALAMAN PENGESAHAN**

**SEGMENTASI AKAR PADA CITRA TANAH DENGAN  
MENGIMPLEMENTASIKAN METODE *ENSEMBLE LEARNING*  
MENGUNAKAN TEKNIK *WEIGHTED AVERAGE* PADA  
ARSITEKTUR *U-NET* DAN *DENSENET***

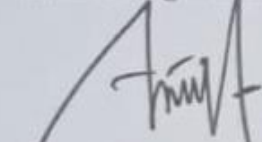
**SKRIPSI**

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
Sarjana Sains Bidang Studi Matematika**

**Oleh**

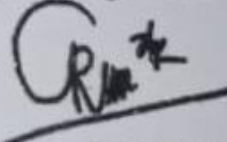
**ANISA AULIA KUSMARENI  
NIM. 08011281823031**

**Pembimbing Kedua**



**Anita Desiani, M.Kom  
NIP. 197712112603122902**

**Indralaya, Agustus 2022  
Pembimbing Utama**



**Sri Indra Maivanti, M.Si  
NIP. 19720704200032001**

**Mengetahui,  
Ketua Jurusan Matematika**



**Drs. Sugandi Yahdin, M.M  
NIP. 19580727198603 1003**

## PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan dibawah ini:

Nama Mahasiswa : Anisa Aulia Kusmareni  
NIM : 08011281823031  
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain.

Semua informasi yang dimuat dalam skripsi ini yang berasal dari penulis lain baik yang dipublikasikan atau tidak telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 26 Desember 2022

Penulis



Anisa Aulia Kusmareni

NIM. 08011281823031

**HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK  
KEPENTINGAN AKADEMIS**

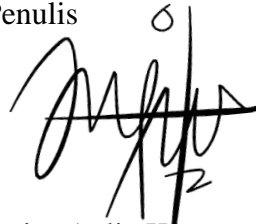
Sebagai Civitas Akademik Universitas Sriwijaya, yang bertanda tangan di bawah ini:

Nama Mahasiswa : Anisa Aulia Kusmareni  
NIM : 08011281823031  
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika  
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Universitas Sriwijaya “Segmentasi Akar Pada Citra Tanah Dengan Mengimplementasikan Metode Ensemble Learning Menggunakan Teknik Weighted Average Pada Arsitektur U-Net Dan Densenet”. Dengan hak bebas royalti non-eksklusif ini Universitas Sriwijaya berhak menyimpan, mengalih, edit/memformat, mengelola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan tugas akhir atau skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik hak cipta. Demikian pernyataan ini saya buat dengan sesungguhnya.

Indralaya, 26 Desember 2022

Penulis



Anisa Aulia Kusmareni

NIM. 08011281823031

## HALAMAN PERSEMBAHAN

*Kupersembahkan skripsi ini untuk:*

*Yang Maha Kuasa Allah Subhanahu Wa Ta'ala*

*Kedua orang tuaku Tercinta,*

*Adikku Tersayang,*

*Keluarga Besarku,*

*Semua Guru dan Dosenku,*

*Sahabat-sahabatku Tersayang,*

*Almamaterku*

Motto :

*“live a life you will remember”*

*Avicii ‘The Night’*

## KATA PENGANTAR

Puji syukur kehadiran Allah Subhanahu Wa Ta'ala yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Segmentasi Akar pada Citra Tanah dengan Mengimplementasikan Metode *Ensemble Learning* menggunakan Teknik *Weighted Average* pada Arsitektur *U-Net* dan *DenseNet*” sebagai salah satu syarat memperoleh gelar sarjana sains bidang studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa proses pembuatan skripsi ini merupakan proses pembelajaran yang sangat berharga serta tak lepas dari kekurangan dan keterbatasan. Dengan segala hormat dan kerendahan hati, penulis mengucapkan terima kasih dan penghargaan kepada:

1. Kedua orang tua tercinta, Baba **Eddy Kusnadi, S.E** dan Umi **Rahmanida, S.Ag** yang telah merawat dan membesarkan hingga bisa sampai dititik ini, selalu mendo'akan setiap langkah penulis, dan seluruh kasih sayang yang telah diberikan hingga tidak bisa penulis sebutkan satu-persatu.
2. Bapak **Drs Sugandi Yahdin, M.M** selaku Ketua Jurusan Matematika FMIPA Universitas Sriwijaya yang telah memberikan arahan dan motivasi kepada penulis selama proses perkuliahan dan Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Sekretaris Jurusan Matematika FMIPA Universitas Sriwijaya yang telah mengarahkan urusan akademik kepada penulis.
3. Ibu **Sri Indra Maiyanti, M.Si** selaku dosen pembimbing utama yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan,

pengarahan dan didikan berharga selama proses pembuatan skripsi, dan perjalanan perkuliahan ini.

4. Ibu **Anita Desiani, M.Kom** selaku dosen pembimbing pendamping yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan, pengarahan dan didikan berharga selama proses pembuatan skripsi, kompetisi atau program mahasiswa, dan perjalanan perkuliahan ini.
5. Ibu **Dr. Yuli Andriani, M.Si** dan Ibu **Indrawati, M.Si** selaku dosen pembahas dan penguji yang telah memberikan tanggapan, kritik serta saran yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
6. Ibu **Sisca Octarina, S.Si., M.Sc** selaku sekretaris tim pelaksana tugas akhir penulis dan Bapak **Drs. Putra B.J. Bangun, M.Sc** selaku ketua tim pelaksana tugas akhir penulis.
7. Ibu **Yulia Resti, S.Si., M.Si., Ph.D** selaku dosen pembimbing akademik yang telah membimbing dan mengarahkan urusan akademik penulis.
8. **Seluruh Dosen** di Jurusan Matematika FMIPA yang telah memberikan ilmu, nasihat, serta bimbingan selama proses perkuliahan dan **seluruh guru** yang telah memberikan ilmu yang sangat bermanfaat hingga mengantarkan penulis pada pendidikan ini.
9. Pak **Irwansyah** selaku admin dan Ibu **Hamidah** selaku pegawai tata usaha Jurusan Matematika FMIPA yang telah membantu penulis selama perkuliahan.
10. Adik tersayang **Ibnu Syarif Hidayatullah** atas dukungan dan motivasinya.

11. Semua sahabat seperjuangan selama masa perkuliahan dan skripsi ini, khususnya **Duck's Fams, Anggota grup AYANG, Tydack Cawa, dan Seluruh Rekan Tim Komputasi** atas semua bantuannya.
12. **Kakak-kakak tingkat angkatan 2016 dan 2017 bidang minat komputasi** yang telah banyak membantu serta berbagi ilmu selama proses skripsi.
13. **Keluarga Matematika 2018, BPH Himastik Gelora Karya, dan rekan-rekan perlombaan** selama perkuliahan.
14. Serta semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga segala kebaikan yang diberikan mendapat balasan terbaik dari Allah.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/mahasiswi Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan pihak yang memerlukan.

Indralaya, Agustus 2022

Penulis



# **ROOT SEGMENTATION ON SOIL IMAGES BY IMPLEMENTING ENSEMBLE LEARNING METHODS USING WEIGHTED AVERAGE TECHNIQUES IN U-NET AND DENSENET ARCHITECTURE**

**By:**

**Anisa Aulia Kusmaren  
08011281823031**

## **ABSTRACT**

The purpose of this study was to obtain an accurate segmentation model in predicting roots using a soil image dataset. This research implements ensemble learning with a weighted average technique on U-Net and DenseNet architectures for root segmentation in soil images. The research stages are data description, data pre-processing, training, testing, and performance evaluation as well as making conclusions. In this study, the results obtained from the performance evaluation of a single architecture, namely accuracy, sensitivity, specificity, precision, F1-Score, and IoU obtained from the U-Net architecture respectively, are 99.69% in this study, 75.75%, 99.76%, 66.63%, 70.87%, and 54.38%. While the results obtained from DenseNet architecture are 99.52%, 71.33%, 99.72%, 66.68%, 67.29%, and 50.71%. The results of the implementation of ensemble learning on U-Net and DenseNet architectures are 99.75%, 92.82%, 99.87%, 92.68%, 92.75%, and 86.49%, respectively. Based on the results obtained, it can be concluded that the implementation of ensemble learning on U-Net and DenseNet architectures can segment the roots of the soil image very well. The implementation of ensemble learning can also improve architectural performance and overcome the problem of overfitting in single architecture segmentation.

Keywords: Segmentation, root, ensemble learning, weighted average.

**SEGMENTASI AKAR PADA CITRA TANAH DENGAN  
MENGIMPLEMENTASIKAN METODE *ENSEMBLE LEARNING*  
MENGUNAKAN TEKNIK *WEIGHTED AVERAGE* PADA  
ARSITEKTUR *U-NET* DAN *DENSENET***

**Oleh:**

**Anisa Aulia Kusmaren  
08011281823031**

**ABSTRAK**

Tujuan penelitian ini adalah memperoleh model segmentasi yang akurat dalam memprediksi akar dengan menggunakan dataset citra tanah. Penelitian ini mengimplementasikan *ensemble learning* dengan teknik *weighted average* pada arsitektur *U-Net* dan *DenseNet* untuk segmentasi akar pada citra tanah. Tahapan penelitian adalah deskripsi data, *pre-processing* data, *training*, *testing*, dan evaluasi kinerja serta membuat kesimpulan. Pada penelitian ini, didapatkan nilai hasil evaluasi kinerja dari arsitektur tunggal yaitu akurasi, sensitivitas, spesifisitas, presisi, *F1-Score*, dan *IoU* yang didapatkan dari arsitektur *U-Net* secara berturut-turut adalah penelitian ini berturut-turut adalah 99,69%, 75,75%, 99,76%, 66,63%, 70,87%, dan 54,38%. Sedangkan hasil yang didapat dari arsitektur *DenseNet* berturut-turut adalah 99,52%, 71,33%, 99,72%, 66,68%, 67,29%, dan 50,71%. Hasil dari implementasi *ensemble learning* pada arsitektur *U-Net* dan *DenseNet* berturut-turut adalah 99,75%, 92,82%, 99,87%, 92,68%, 92,75%, dan 86,49%. Berdasarkan hasil yang didapatkan, dapat ditarik kesimpulan bahwa implementasi *ensemble learning* pada arsitektur *U-Net* dan *DenseNet* dapat mensegmentasikan akar pada citra tanah dengan sangat baik. Implementasi dari *ensemble learning* juga dapat meningkatkan kinerja arsitektur dan mengatasi masalah *overfitting* pada segmentasi arsitektur tunggal.

Kata Kunci: Segmentasi, akar, *ensemble learning*, *weighted average*.

## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>HALAMAN PENGESAHAN.....</b>	<b>ii</b>
<b>HALAMAN PERSEMBAHAN .....</b>	<b>v</b>
<b>KATA PENGANTAR.....</b>	<b>vi</b>
<b>ABSTRACT .....</b>	<b>ix</b>
<b>ABSTRAK .....</b>	<b>x</b>
<b>DAFTAR ISI.....</b>	<b>xi</b>
<b>DAFTAR TABEL .....</b>	<b>xiii</b>
<b>DAFTAR GAMBAR.....</b>	<b>xiv</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Perumusan Masalah.....	5
1.3 Pembatasan Masalah .....	5
1.4 Tujuan.....	6
1.5 Manfaat.....	6
<b>BAB II TINJAUAN PUSTAKA .....</b>	<b>7</b>
2.1 Citra Tanah .....	7
2.2 Citra Digital.....	7
2.3 <i>Pre-processing</i> Citra .....	8
2.3.1 <i>Color Jitter</i> .....	8
2.3.2 <i>Elastic Grid Deformation</i> .....	8
2.4 <i>Convolutional Neural Networks (CNN)</i> .....	9
2.4.1 <i>Convolutional Layer</i> .....	9
2.4.2 <i>Pooling Layer</i> .....	10
2.4.3 <i>Batch Normalization</i> .....	13
2.4.4 Fungsi Aktivasi.....	14
2.4.5 <i>Upsampling Layer</i> .....	15
2.4.6 <i>Concatenate Layer</i> .....	16
2.4.7 <i>Loss Function: Binary Cross Entropy</i> .....	16
2.5 <i>U-Net</i> .....	17
2.6 <i>Densely Connected Convolutional (DenseNet)</i> .....	18

2.7	<i>Ensemble Learning</i> .....	19
2.8	<i>Confusion Matrix</i> .....	20
<b>BAB III</b> .....		<b>24</b>
3.1	Tempat.....	24
3.2	Waktu .....	24
3.3	Alat .....	24
3.4	Metode Penelitian.....	24
<b>BAB IV HASIL DAN PEMBAHASAN</b> .....		<b>31</b>
4.1	Deskripsi Data .....	31
4.2	<i>Pre-processing</i> .....	33
4.3	Operasi Manual <i>Convolutional Neural Network (CNN)</i> .....	35
	4.3.1 <i>Convolutional Layer</i> .....	35
	4.3.2 <i>Pooling Layer</i> .....	37
	4.3.3 <i>Batch Normalization</i> .....	41
	4.3.4 Fungsi Aktivasi.....	44
	4.3.5 <i>Upsampling Layer</i> .....	46
	4.3.6 <i>Concatenate</i> .....	47
	4.3.7 <i>Binary Cross-entropy</i> .....	48
	4.3.8 <i>Weighted Average</i> .....	49
4.4	Segmentasi Citra .....	50
	4.4.1 <i>U-Net</i> .....	50
	4.4.2 <i>DenseNet</i> .....	55
	4.4.3 <i>Ensemble Learning</i> .....	61
4.5	Analisis Hasil dan Kesimpulan .....	67
<b>BAB V KESIMPULAN DAN SARAN</b> .....		<b>69</b>
5.1	Kesimpulan.....	69
5.2	Saran.....	69
<b>DAFTAR PUSTAKA</b> .....		<b>70</b>

## DAFTAR TABEL

Tabel 2.1 <i>Confusion Matrix</i> Segmentasi Akar Pada Citra Tanah.....	20
Tabel 2.2 Kategori Kinerja Arsitektur .....	22
Tabel 4.1 Sampel Citra Tanah.....	29
Tabel 4.2 <i>Confusion Matrix</i> Proses <i>Testing U-Net</i> .....	51
Tabel 4.3 <i>Confusion Matrix</i> Proses <i>Testing DenseNet</i> .....	55
Tabel 4.4 <i>Confusion Matrix</i> Proses <i>Testing Ensemble Learning</i> .....	61
Tabel 4.5 Perbandingan Hasil Segmentasi Dari <i>U-Net</i> , <i>Densenet</i> Dan EL.....	63
Tabel 4.6 Perbandingan Hasil Segmentasi Dengan Penelitian Lain.....	64

## DAFTAR GAMBAR

Gambar 2.1. Citra Tanah.....	7
Gambar 2.2. Proses <i>Convolution Layer</i> .....	10
Gambar 2.3. <i>Max pooling</i> .....	11
Gambar 2.4. <i>Average pooling</i> .....	12
Gambar 2.5. <i>Global average pooling</i> .....	12
Gambar 2.6. Representasi Fungsi Aktivasi <i>ReLU</i> .....	14
Gambar 2.7. <i>Upsampling Layer</i> .....	15
Gambar 2.8. Arsitektur <i>U-Net</i> .....	17
Gambar 2.9. Arsitektur <i>DenseNet</i> .....	19
Gambar 4.1. Citra Tanah dan <i>Ground Truth</i> .....	33
Gambar 4. 2 Hasil <i>pre-processing</i> , citra asli <i>color jitter</i> dan, EGD .....	34
Gambar 4.3. Ilustrasi Proses Partisi <i>Max Pooling</i> .....	38
Gambar 4.4. Ilustrasi Proses Partisi <i>Average Pooling</i> .....	40
Gambar 4.5. Ilustrasi <i>Concatenate</i> .....	48
Gambar 4.6. Grafik Akurasi <i>Training U-Net</i> .....	51
Gambar 4.7. Grafik <i>Loss Training U-Net</i> .....	51
Gambar 4.8. Perbandingan Hasil Segmentasi <i>U-Net</i> dan <i>GroundTruth</i> .....	52
Gambar 4.9. Grafik Akurasi <i>Training DenseNet</i> .....	56
Gambar 4.10. Grafik <i>Loss Training DenseNet</i> .....	57
Gambar 4.11. Perbandingan Hasil Segmentasi <i>DenseNet</i> dan <i>Ground Truth</i> .....	57
Gambar 4.12. Proses <i>training ensemble learning</i> .....	61
Gambar 4.13. Grafik Akurasi <i>Training Ensemble Learning</i> .....	62
Gambar 4.14. Grafik <i>Loss Training Ensemble Learning</i> .....	62
Gambar 4. 15 Perbandingan Hasil Segmentasi <i>Ensemble Learning</i> dan <i>Ground Truth</i> ...	63

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

*Machine Learning* (ML) merupakan sebuah teknologi dalam mengenali pola data dengan pendekatan model statistik yang berkembang sangat pesat dalam beberapa dekade terakhir (Carleo *et al.*, 2019). *Deep Learning* (DL) merupakan sub bidang dari ML yang mempelajari abstraksi pada data dengan level yang lebih tinggi dengan memanfaatkan arsitektur yang terstruktur (Guo *et al.*, 2016). Implementasi dari DL sangat sering digunakan pada proses segmentasi citra. Segmentasi citra merupakan bagian dari pengolahan sebuah citra dimana citra tersebut dibagi menjadi beberapa bagian dengan tujuan menemukan objek pada citra (Yuheng & Hao, 2017). Segmentasi citra telah banyak digunakan dalam berbagai bidang, salah satunya adalah bidang agrikultur yang telah banyak digunakan dalam penelitian terhadap komponen pada tanaman (Liakos *et al.*, 2018).

Salah satu komponen yang sangat penting dari tanaman adalah akar. Bentuk dari akar dipengaruhi oleh lingkungan disekitarnya sehingga sangat dibutuhkan dalam keperluan berbagai penelitian yang berkaitan dengan tanaman (Maeght *et al.*, 2013). Terdapat empat parameter utama yang menentukan bentuk dari akar yaitu pertumbuhan, cabang, luas permukaan, dan sudut dimana parameter tersebut dipengaruhi oleh respon tanaman terhadap lingkungan tanah di sekitarnya seperti ketersediaan air ataupun nutrisi pada tanah (Morris *et al.*, 2017). Sayangnya, untuk mendeteksi akar pada citra tanah secara manual membutuhkan waktu yang cukup

lama dan pengawasan dengan ketelitian yang tinggi pada prosesnya (Cai *et al.*, 2015). Selain metode manual, Morris *et al.* (2017) telah melakukan penelitian dengan menggunakan metode 3D seperti *X-Ray* dengan komputasi tomografi dan Stingaciu *et al.* (2013) dengan resonansi magnetik untuk segmentasi akar pada citra tanah, namun kedua metode tersebut membutuhkan biaya yang sangat mahal dan hanya dapat dilakukan dengan sampel yang sedikit.

Salah satu cara yang efisien untuk mendeteksi akar pada citra tanah adalah dengan segmentasi citra menggunakan metode *Convolution Neural Network* (CNN). CNN merupakan salah satu metode dari segmentasi citra yang paling baik dan paling banyak digunakan yang dapat mendeteksi dan mengenali objek dalam citra digital dengan baik (Hashemi, 2019; Minaee *et al.*, 2021). Kinerja dari CNN pada segmentasi citra yaitu melakukan proses konvolusi dengan menggerakkan *convolution kernel* berukuran  $n \times n$  pada sebuah citra sehingga didapatkan informasi representatif terbaru yang didapatkan dari hasil perkalian bagian citra dengan *convolution kernel* yang digunakan (Kuo, 2016).

*U-Net* merupakan salah satu arsitektur dari CNN yang dikembangkan oleh Ronneberger, Fischer and Brox (2015) pada segmentasi citra biomedis. Pada *U-Net* terdapat dua jalur yaitu *encoder* dan *decoder*, dimana pada *encoder* terdapat lapisan *convolution* dan *max pooling*. Sedangkan pada jalur *decoder* berfungsi untuk melokasikan secara tepat dengan menggunakan lapisan *convolution* (Chen *et al.*, 2018; Ronneberger *et al.*, 2015). Sayangnya, lapisan dari *U-Net* yang tidak terlalu mendalam dibandingkan dari arsitektur CNN lainnya, sehingga dibutuhkan lapisan tambahan yang apabila berlebihan dapat menyebabkan parameter membesar



sehingga dapat membuat gradien hilang pada saat *Training* (Chen *et al.*, 2018). Beberapa penelitian segmentasi citra yang menggunakan *U-Net* diantaranya adalah penelitian oleh Kassim *et al.* (2019) pada segmentasi pembuluh darah arteriol dan venula pada jaringan durameter tikus dengan nilai akurasi 98,4%, dan *F1-Score* 88%. Selanjutnya penelitian oleh Xiao *et al.* (2020) pada segmentasi nodul pada paru-paru didapatkan sensitivitas sebesar 99,1% dan *F1-Score* sebesar 95,30%. Dan penelitian oleh Sathananthavathi & Indumathi (2021) pada segmentasi pembuluh darah pada retina dengan nilai akurasi 94,45%, sensitivitas 80,21%, dan spesifisitas 95,61%. Sayangnya dari ketiga penelitian tersebut, tidak ada yang menghitung nilai presisi dan *IoU*.

Arsitektur lainnya dari CNN adalah *Densely Connected Convolutional Network (DenseNet)*. *DenseNet* adalah arsitektur yang setiap lapisannya langsung terkoneksi ke semua lapisan-lapisan berikutnya sehingga didapatkan peningkatan pada penggunaan fitur lapisan selanjutnya terdiri dari lapisan *Dense Block* dan dapat mengatasi hilangnya gradien dengan tidak menambah jumlah parameter (Huang *et al.*, 2017; Wu *et al.*, 2019). Sayangnya, karena fitur lapisan-lapisan tersebut membuat kinerja *DenseNet* membutuhkan waktu lebih lama dan memori yang lebih banya dibandingkan arsitektur CNN lainnya (Zhang *et al.*, 2021). Penelitian menggunakan arsitektur *DenseNet* juga telah banyak digunakan pada segmentasi citra, diantaranya adalah penelitian oleh Zhang *et al.* (2021) pada segmentasi nodul pada paru-paru dengan nilai akurasi 99,97%, sensitivitas 79,36%, dan spesifisitas 99,98%. Selanjutnya adalah penelitian oleh Gottapu & Dagli (2018) pada segmentasi anatomi pada otak didapatkan nilai akurasi 90,52% dan *F1-Score*

67,3%. Kemudian penelitian oleh Vila *et al.* (2020), pada segmentasi plak pada ultrasonografi arteri arotis didapatkan nilai akurasi 96,45%, sensitivitas 80%, dan spesifisitas 96,63%. Namun, dari ketiga penelitian tersebut tidak ada yang menghitung hasil presisi dan *IoU*.

Setiap arsitektur memiliki kelebihan dan kekurangan yang dapat diterapkan dengan menggunakan metode *ensemble learning*. *Ensemble Learning* (EL) merupakan sebuah metode pada ML yang menggabungkan beberapa model untuk membuat sebuah keputusan dengan menggabungkan beberapa model dan apabila salah satu dari model tersebut terdapat sebuah kelemahan, maka akan dikompensasi dari model lainnya yang selanjutnya akan didapatkan hasil yang lebih baik daripada menggunakan model tunggal (Sagi & Rokach, 2018). Pada EL terdapat beberapa metode dan salah satu diantaranya yang sering digunakan adalah *weighted average* (Witten *et al.*, 2017). Beberapa penelitian yang menggunakan EL dengan metode *weighted average* beberapa diantaranya adalah penelitian oleh Liu *et al.* (2020) pada segmentasi pankreas dengan menggabungkan model *ResNet* dan *FCN* didapatkan nilai sensitivitas 85,33%, presisi 83,60%, *F1-Score* 84,10% dan *IoU* 72,86%. Selanjutnya penelitian oleh Abdollahi *et al.*, (2020) pada segmentasi bangunan dengan model *SegNet* dan *U-Net* didapatkan nilai akurasi 92,33%. Dan penelitian oleh Wang *et al.*, (2015) pada segmentasi pembuluh darah retina dengan hasil akurasi 98,13%, sensitivitas 81,04% dan spesifisitas 97,91%.

Pada penelitian ini, dilakukan segmentasi akar pada citra tanah dengan implementasi EL menggunakan teknik *weighted average* pada arsitektur *U-Net* dan *DenseNet*. Kekurangan yang dimiliki *U-Net* yang membutuhkan *layer* yang lebih

mendalami dan *DenseNet* yang memiliki beberapa *layer* tambahan pada arsitekturnya diimplementasikan pada EL dan diharapkan mendapat hasil yang akurat. Hasil evaluasi dari kinerja arsitektur akan dibandingkan dan dievaluasi berdasarkan nilai akurasi, sensitivitas, spesifisitas, presisi, *F1-Score*, dan *IoU*.

## 1.2 Perumusan Masalah

Rumusan masalah dari penelitian ini adalah bagaimana implementasi dari *ensemble learning* dengan metode *weighted average* pada hasil kinerja *U-Net* dan *DenseNet* dalam meningkatkan keakuratan segmentasi akar pada citra tanah yang akan dibandingkan dan dievaluasi berdasarkan nilai akurasi, sensitivitas, spesifisitas, presisi, *F1-Score*, dan *IoU*.

## 1.3 Pembatasan Masalah

Pembatasan masalah dalam penelitian ini adalah sebagai berikut :

1. Penelitian ini hanya membahas mengenai segmentasi akar pada citra tanah.
2. Penelitian ini tidak membahas mengenai klasifikasi dari bentuk akar.
3. Kriteria penilaian yang dilakukan dalam segmentasi akar pada citra tanah berdasarkan nilai akurasi, sensitivitas, spesifisitas, presisi, *F1-Score*, dan *IoU*.

## 1.4 Tujuan

Penelitian ini bertujuan untuk mengimplementasikan *ensemble learning* agar dapat meningkatkan hasil kinerja arsitektur *U-Net* dan *DenseNet* sehingga memperoleh hasil yang akurat pada segmentasi akar pada citra tanah dengan acuan nilai kinerja akurasi, sensitivitas, spesifisitas, presisi, *F1-Score*, dan *IoU*.

## 1.5 Manfaat

Manfaat penelitian ini adalah :

1. Dapat dijadikan model baru untuk segmentasi akar pada citra tanah yang akurat.
2. Dapat dijadikan referensi penelitian yang melibatkan arsitektur akar.
3. Dapat dijadikan sebagai *input* untuk klasifikasi arsitektur akar.

## DAFTAR PUSTAKA

- Abdollahi, A., Pradhan, B., & Alamri, A. M. (2020). An ensemble architecture of deep convolutional Segnet and Unet networks for building semantic segmentation from high-resolution aerial images. *Geocarto International*, 2(12), 000. <https://doi.org/10.1080/10106049.2020.1856199>
- Agarap, A. F. (2018). *Deep Learning using Rectified Linear Units (ReLU)*. 2(3).
- Albahli, S., Nazir, T., Irtaza, A., & Javed, A. (2021). Recognition and detection of diabetic retinopathy using densenet-65 based faster-rcnn. *Computers, Materials and Continua*, 67(2), 1333–1351. <https://doi.org/10.32604/cmc.2021.014691>
- Albawi, S., Mohammed, T. A. M., & Alzawi, S. (2017). Layers of a convolutional neural network. *Ieee*, 16.
- Azizi, A., Abbaspour-Gilandeh, Y., Vannier, E., Dusséaux, R., Mseri-Gundoshmian, T., & Moghaddam, H. A. (2020). Semantic segmentation: A modern approach for identifying soil clods in precision farming. *Biosystems Engineering*, 196, 172–182. <https://doi.org/10.1016/j.biosystemseng.2020.05.022>
- Banerjee, K., Vishak Prasad, C., Gupta, R. R., Vyas, K., Anushree, H., & Mishra, B. (2021). Exploring alternatives to softmax function. *Proceedings of the 2nd International Conference on Deep Learning Theory and Applications, DeLTA 2021*, 81–86. <https://doi.org/10.5220/0010502000810086>
- Beauxis-aussalet, E., & Hardman, L. (2014). Visualization of confusion matrix for non-expert users. *IEEE Information Visualization (InfoVis 2014)*.
- Cai, J., Zeng, Z., Connor, J. N., Huang, C. Y., Melino, V., Kumar, P., & Miklavcic, S. J. (2015). RootGraph: A graphic optimization tool for automated image analysis of plant roots. *Journal of Experimental Botany*, 66(21), 6551–6562. <https://doi.org/10.1093/jxb/erv359>
- Carleo, G., Cirac, I., Cranmer, K., Daudet, L., Schuld, M., Tishby, N., Vogt-Maranto, L., & Zdeborová, L. (2019). Machine learning and the physical sciences. *Reviews of Modern Physics*, 91(4), 45002. <https://doi.org/10.1103/RevModPhys.91.045002>
- Chen, L., Bentley, P., Mori, K., Misawa, K., Fujiwara, M., & Rueckert, D. (2018). DRINet for medical image segmentation. *IEEE Transactions on Medical Imaging*, 37(11), 2453–2462. <https://doi.org/10.1109/TMI.2018.2835303>
- Christlein, V., Spranger, L., Seuret, M., Nicolaou, A., Král, P., & Maier, A. (2019). Deep Generalized Max Pooling. *2019 International Conference on Document Analysis and Recognition (ICDAR)*, 1090–1096.

<https://doi.org/10.1109/ICDAR.2019.00177>

- Desiani, A., Yahdin, S., & Kartikasari, A. (2021). *Handling the imbalanced data with missing value elimination SMOTE in the classification of the relevance education background with graduates employment*. 10(2), 346–354. <https://doi.org/10.11591/ijai.v10.i2.pp346-354>
- Gong, L., Du, X., Zhu, K., Lin, C., Lin, K., Wang, T., Lou, Q., Yuan, Z., Huang, G., & Liu, C. (2021). Pixel level segmentation of early-stage in-bag rice root for its architecture analysis. *Computers and Electronics in Agriculture*, 186(April), 106197. <https://doi.org/10.1016/j.compag.2021.106197>
- Gottapu, R. D., & Dagli, C. H. (2018). DenseNet for anatomical brain segmentation. *Procedia Computer Science*, 140, 179–185. <https://doi.org/10.1016/j.procs.2018.10.327>
- Guo, T., Dong, J., & Li, H. (2017). Simple Convolutional Neural Network on image classification. *IEEE International Conference on Big Data Analysis*, 721–724.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48. <https://doi.org/10.1016/j.neucom.2015.09.116>
- Hashemi, M. (2019). Enlarging smaller images before inputting into convolutional neural network: zero-padding vs. interpolation. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0263-7>
- Huang, G., Liu, Z., Maaten, L. van der, & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *American Journal of Veterinary Research*, 39(9), 1442–1446.
- Islam, M. M., Poly, T. N., Walther, B. A., Yang, H. C., & Li, Y. C. (2020). Artificial intelligence in ophthalmology: A meta-analysis of deep learning models for retinal vessels segmentation. *Journal of Clinical Medicine*, 9(4). <https://doi.org/10.3390/jcm9041018>
- Kassim, Y. M., Glinskii, O. V., Glinsky, V. V., Huxley, V. H., Guidoboni, G., & Palaniappan, K. (2019). Deep U-Net Regression and Hand-Crafted Feature Fusion for accurate blood vessel segmentation. *Proceedings - International Conference on Image Processing, ICIP, 2019-Septe*, 1445–1449. <https://doi.org/10.1109/ICIP.2019.8803084>
- Kayal, S., Dubost, F., Tiddens, H. A. W. M., & Bruijne, M. De. (2020). *Spectral data augmentation techniques to quantify lung pathology from ct-images*. 1(2), 586–590.
- Kuo, C. J. (2016). Understanding Convolutional Neural Networks with a mathematical model. *Journal of Visual Communication and Image Representation*, 2(November). <https://doi.org/10.1016/j.jvcir.2016.11.003>
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. (2014). Medical

- image classification with convolutional neural network. *2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014*, 844–848. <https://doi.org/10.1109/ICARCV.2014.7064414>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors (Switzerland)*, *18*(8), 1–29. <https://doi.org/10.3390/s18082674>
- Lian, S., Li, L., Lian, G., Xiao, X., Luo, Z., & Li, S. (2019). A global and local enhanced Residual U-Net for accurate retinal vessel segmentation. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, *14*(8), 1–10. <https://doi.org/10.1109/tcbb.2019.2917188>
- Liu, S., Yuan, X., Hu, R., Liang, S., Feng, S., Ai, Y., & Zhang, Y. (2020). Automatic pancreas segmentation via Coarse Location and Ensemble Learning. *IEEE Access*, *8*, 2906–2914. <https://doi.org/10.1109/ACCESS.2019.2961125>
- Loffe, S., & Szegedy, C. (2015). Batch normalization: accelerating deep network training by reducing internal covariate shift. *Proceedings of the 32nd International Conference on Machine Learning*, *37*, 448–456. <https://doi.org/10.1080/17512786.2015.1058180>
- Maeght, J. L., Rewald, B., & Pierret, A. (2013). How to study deep roots-and why it matters. *Frontiers in Plant Science*, *4*(AUG), 1–14. <https://doi.org/10.3389/fpls.2013.00299>
- Minaee, S., Boykov, Y. Y., Porikli, F., Plaza, A. J., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using Deep Learning: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *8828*(c), 1–20. <https://doi.org/10.1109/TPAMI.2021.3059968>
- Mishra, S., Vanli, O. A., Huffer, F. W., & Jung, S. (2016). Regularized discriminant analysis for multi-sensor decision fusion and damage detection with Lamb waves. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, *9803*(850), 98032H. <https://doi.org/10.1117/12.2217959>
- Misra, S., & Wu, Y. (2019). Machine learning assisted segmentation of scanning electron microscopy images of organic-rich shales with feature extraction and feature ranking. In *Machine Learning for Subsurface Characterization*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-817736-5.00010-7>
- Morris, E. C., Griffiths, M., Golebiowska, A., Mairhofer, S., Burr-Hersey, J., Goh, T., von Wangenheim, D., Atkinson, B., Sturrock, C. J., Lynch, J. P., Vissenberg, K., Ritz, K., Wells, D. M., Mooney, S. J., & Bennett, M. J. (2017). Shaping 3D root system architecture. *Current Biology*, *27*(17), R919–R930. <https://doi.org/10.1016/j.cub.2017.06.043>
- Narisetti, N., Henke, M., Seiler, C., Shi, R., Junker, A., Altmann, T., & Gladilin, E.

- (2019). Semi-automated Root Image Analysis (saRIA). *Scientific Reports*, 9(1), 1–10. <https://doi.org/10.1038/s41598-019-55876-3>
- Nemade, S. B., & Sonavane, S. P. (2019). Image segmentation using Convolutional Neural Network for image annotation. *Proceedings of the 4th International Conference on Communication and Electronics Systems, ICCES 2019*, 8(11), 838–843. <https://doi.org/10.1109/ICCES45898.2019.9002121>
- Pauly, L., Peel, H., Luo, S., Hogg, D., & Fuentes, R. (2017). Deeper networks for pavement crack detection. *ISARC 2017 - Proceedings of the 34th International Symposium on Automation and Robotics in Construction, Isarc*, 479–485. <https://doi.org/10.22260/isarc2017/0066>
- Reddy, G. T., Bhattacharya, S., Siva Ramakrishnan, S., Chowdhary, C. L., Hakak, S., Kaluri, R., & Praveen Kumar Reddy, M. (2020). An ensemble based machine learning model for diabetic retinopathy classification. *International Conference on Emerging Trends in Information Technology and Engineering, Ic-ETITE 2020*, 1–6. <https://doi.org/10.1109/ic-ETITE47903.2020.235>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for biomedical image segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9351(Cvd), 12–20. <https://doi.org/10.1007/978-3-319-24574-4>
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), 1–18. <https://doi.org/10.1002/widm.1249>
- Sathananthavathi, V., & Indumathi, G. (2021). Encoder Enhanced Atrous (EEA) Unet architecture for Retinal blood vessel segmentation. *Cognitive Systems Research*, 67, 84–95. <https://doi.org/10.1016/j.cogsys.2021.01.003>
- Smith, A. G., Petersen, J., Selvan, R., & Rasmussen, C. R. (2020). Segmentation of roots in soil with U-Net. *Plant Methods*, 16(1), 1–15. <https://doi.org/10.1186/s13007-020-0563-0>
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., & Paul, M. (2019). Deep learning models for retinal blood vessels segmentation: A review. *IEEE Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Stingaciu, L., Schulz, H., Pohlmeier, A., Behnke, S., Zilken, H., Javaux, M., & Vereecken, H. (2013). In situ root system architecture extraction from magnetic resonance imaging for water uptake modeling. *Vadose Zone Journal*, 12(1), vzj2012.0019. <https://doi.org/10.2136/vzj2012.0019>
- Sun, M., Song, Z., Jiang, X., Pan, J., & Pang, Y. (2017). Learning pooling for convolutional neural network. *Neurocomputing*, 224, 96–104. <https://doi.org/10.1016/j.neucom.2016.10.049>



- Takahashi, R., Matsubara, T., Uehara, K., Zhu, J., & Takeuchi, I. (2018). RICAP: Random Image Cropping and Patching Data augmentation for deep CNNs. *Proceedings of Machine Learning Research*, 95(2012), 786–798. <https://github.com/facebook/fb.resnet.torch>.
- Tyagi, V. (2018). Understanding digital image processing. *Understanding Digital Image Processing*, November. <https://doi.org/10.1201/9781315123905>
- Vila, M. del M., Remeseiro, B., Grau, M., Elosua, R., Betriu, À., Fernandez-Giraldez, E., & Igual, L. (2020). Semantic segmentation with DenseNets for carotid artery ultrasound plaque segmentation and CIMT estimation. *Artificial Intelligence in Medicine*, 103, 101784. <https://doi.org/10.1016/j.artmed.2019.101784>
- Wang, S. H., Tang, C., Sun, J., Yang, J., Huang, C., Phillips, P., & Zhang, Y. D. (2018). Multiple sclerosis identification by 14-layer convolutional neural network with batch normalization, dropout, and stochastic pooling. *Frontiers in Neuroscience*, 12(NOV), 1–11. <https://doi.org/10.3389/fnins.2018.00818>
- Wang, S., Yin, Y., Cao, G., Wei, B., Zheng, Y., & Yang, G. (2015). Hierarchical retinal blood vessel segmentation based on feature and ensemble learning. *Neurocomputing*, 149(PB), 708–717. <https://doi.org/10.1016/j.neucom.2014.07.059>
- Wang, T., Rostamza, M., Song, Z., Wang, L., McNickle, G., Iyer-Pascuzzi, A. S., Qiu, Z., & Jin, J. (2019). SegRoot: A high throughput segmentation method for root image analysis. *Computers and Electronics in Agriculture*, 162(February), 845–854. <https://doi.org/10.1016/j.compag.2019.05.017>
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2017). Ensemble learning. *Data Mining*, 479–501. <https://doi.org/10.1016/b978-0-12-804291-5.00012-x>
- Wu, C., Zou, Y., & Zhan, J. (2019). DA-U-Net: Densely Connected Convolutional Networks and Decoder with Attention Gate for retinal vessel segmentation. *IOP Conference Series: Materials Science and Engineering*, 533(1), 0–7. <https://doi.org/10.1088/1757-899X/533/1/012053>
- Xiao, Z., Liu, B., Geng, L., Zhang, F., & Liu, Y. (2020). Segmentation of lung nodules using improved 3D-UNet neural network. *Symmetry*, 12(11), 1–15. <https://doi.org/10.3390/sym12111787>
- Yuheng, S., & Hao, Y. (2017). *Image segmentation algorithms overview*. 1. <http://arxiv.org/abs/1707.02051>
- Zeng, G. (2020). On the confusion matrix in credit scoring and its analytical properties. *Communications in Statistics - Theory and Methods*, 49(9), 2080–2093. <https://doi.org/10.1080/03610926.2019.1568485>
- Zhang, C., Benz, P., Argaw, D. M., Lee, S., Kim, J., Rameau, F., Bazin, J. C., & Kweon, I. S. (2021). ResNet or DenseNet? Introducing dense shortcuts to ResNet. *Proceedings - 2021 IEEE Winter Conference on Applications of*

*Computer Vision, WACV 2021*, 3549–3558.  
<https://doi.org/10.1109/WACV48630.2021.00359>

Zhang, X., Li, S., Zhang, B., Dong, J., Zhao, S., & Liu, X. (2021). Automatic detection and segmentation of lung nodules in different locations from CT images based on adaptive  $\alpha$ -hull algorithm and DenseNet convolutional network. *International Journal of Imaging Systems and Technology*, 31(4), 1882–1893. <https://doi.org/10.1002/ima.22580>