

**PENERAPAN METODE *ENSEMBLE LEARNING*  
PADA HASIL *U-NET* DAN *RESNET*  
MENGUNAKAN TEKNIK *WEIGHTED VOTING*  
UNTUK SEGMENTASI AKAR PADA TANAH**

**SKRIPSI**

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

**Oleh :**

**MUHAMMAD WAHYU ILAHI**

**NIM. 08011381823062**



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

**2022**

**LEMBAR PENGESAHAN**

**PENERAPAN METODE *ENSEMBLE LEARNING*  
PADA HASIL *U-NET* DAN *RESNET*  
MENGUNAKAN TEKNIK *WEIGHTED VOTING*  
UNTUK SEGMENTASI AKAR PADA TANAH**

**SKRIPSI**

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

**Oleh :**

**MUHAMMAD WAHYU ILAHI**

**NIM. 08011381823062**

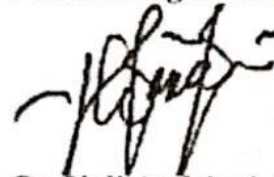
**Indralaya, 1 Agustus 2022**

**Pembimbing Kedua**



**Anita Desiani, M.Kom  
NIP. 197712112003122002**

**Pembimbing Utama**



**Dr. Yuli Andriani, M.Si  
NIP. 197207021999032001**

**Mengetahui,**

**Ketua Jurusan Matematika**



**Drs. Sugandi Yahdin, M.M  
NIP. 195807271986031003**

## PERNYATAAN

Saya yang bertanda tangan di bawah ini :

Nama : Muhammad Wahyu Ilahi

NIM : 08011381823062

Jurusan : Matematika

Menyatakan dengan ini saya bersungguh-sungguh bahwa skripsi yang berjudul “Penerapan Metode *Ensemble Learning* pada Hasil *U-Net* dan *ResNet* menggunakan Teknik *Weighted Voting* untuk Segmentasi Akar pada Tanah” merupakan karya yang saya susun sendiri dan saya tidak melakukan penjiplakan dari karya manapun serta saya melakukan pengutipan sesuai dengan pedoman keilmuan yang berlaku seperti tertuang dalam Peraturan Menteri Pendidikan Nasional Republik Indonesia Nomor 17 Tahun 2010 terkait Pencegahan dan Penanggulangan Plagiat di Perguruan Tinggi.

Apabila dikemudian hari, terdapat pelanggaran yang ditemukan dalam skripsi saya ataupun adanya pengaduan dari pihak lain terhadap keaslian skripsi saya, maka saya bersedia menanggung sanksi yang dijatuhkan kepada saya.

Demikianlah pernyataan ini dibuat dengan sungguh-sungguh tanpa adanya paksaan dari pihak manapun.

Indralaya, 01 Agustus 2022

Yang membuat pernyataan,



Muhammad Wahyu Ilahi

NIM. 08011381823062

## **LEMBAR PERSEMBAHAN**

*Kupersembahkan skripsi ini untuk :*

*Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,*

*Suri Tauladan Nabi Muhammad Shallallahu 'Alaihi Wa Sallam,*

*Kedua orang tuaku tersayang,*

*Kakak perempuan dan Adik-adikku,*

*Keluarga besarku,*

*Semua guru dan dosenku,*

*Sahabat-sahabatku,*

*Almamaterku.*

Moto

*“Banggalah pada Diri Sendiri dan Janganlah Sombong”*

## KATA PENGANTAR

Puji syukur kehadiran Allah Subhanahu Wa Ta'ala yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Penerapan Metode *Ensemble Learning* pada Hasil *U-Net* dan *ResNet* Menggunakan Teknik *Weighted Voting* untuk Segmentasi Akar pada Tanah” Sebagai Salah Satu Syarat Memperoleh Gelar Sarjana Matematika di Fakultas Matematika dan Ilmu Pengetahuan Alam 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 tuaku tercinta, **M.Cholik** dan **Darmiati**, yang tak pernah lelah mendidik, menasehati, membimbing, mendukung dan terus mendoakan penulis. Terima kasih atas segala perjuangan dan pengorbanan hingga detik ini dan sampai kapanpun.
2. Bapak **Prof. Hermansyah, M.Si. Ph.D** selaku Dekan FMIPA Universitas Sriwijaya yang telah memimpin penyelenggaraan pendidikan, penelitian, pengabdian pada masyarakat dan lain-lain.
3. Bapak **Drs. Sugandi Yahdin, M.M** selaku Ketua Jurusan Matematika FMIPA Universitas Sriwijaya yang telah memberikan arahan dan motivasi kepada penulis selama proses perkuliahan.

4. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Sekretaris Jurusan Matematika FMIPA Universitas Sriwijaya yang telah mengarahkan urusan akademik kepada penulis.
5. Ibu **Dr. Yuli Andriani, M.Si** selaku dosen pembimbing akademik sekaligus pembimbing utama skripsi yang telah membimbing dan mengarahkan urusan akademik dari awal hingga akhir serta yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan selama proses pembuatan skripsi ini dengan penuh pengertian kepada penulis.
6. Ibu **Anita Desiani, S.Si., M.Kom** selaku dosen pembimbing kedua skripsi yang telah bersedia meluangkan waktu, tenaga, pikiran, memberikan bimbingan, pengarahan, dan didikan berharga selama proses pembuatan skripsi, kompetisi atau program mahasiswa selama jalannya perkuliahan ini.
7. Ibu **Dra. Ning Eliyati, M.Pd** dan Ibu **Oki Dwipurwani, M.Si** selaku dosen pembahas pertama dan kedua yang telah memberikan tanggapan, kritik, dan saran yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
8. Ibu **Sri Indra Maiyanti, M.Si** dan Ibu **Dr.Ir. Herlina Hanum, M.Si** selaku ketua dan sekretaris sidang skripsi yang telah mengurus serta memandu jalannya sidang dari awal hingga akhir penyelesaian skripsi ini.
9. **Seluruh Dosen dan Guru** yang telah memberikan ilmu yang bermanfaat, nasihat, motivasi, serta bimbingan hingga saat ini.
10. Bapak **Irwansyah** selaku admin dan Ibu **Hamidah** selaku pegawai tata usaha Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.

11. **Kakak Perempuan, Adik-adik dan Keluarga Besarku** yang selalu mendoakan, memberi nasihat yang berharga, dan menjadi teman diskusi terbaik selama ini yang selalu mendukung penulis.
12. **Semua Sahabatku**, terimakasih sudah menjadi orang-orang baik di sekeliling penulis yang selalu mendukung, membantu dengan tulus, mendoakan dan memberi energi positif.
13. **Kakak dan Adik Tingkat**, terima kasih atas segala kebaikannya.
14. **Semua Pihak** yang tidak dapat penulis sebutkan satu per satu. Semoga segala kebaikan yang diberikan mendapat balasan terbaik dari Allah Subhanahu Wa Ta'ala.

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

Indralaya, 1 Agustus 2022

Penulis

**APPLICATION OF *ENSEMBLE LEARNING* METHOD  
IN *U-NET* AND *RESNET* RESULTS  
USING *WEIGHTED VOTING* TECHNIQUE  
FOR SEGMENTATION OF ROOTS IN SOIL**

**By :  
MUHAMMAD WAHYU ILAHI  
NIM. 08011381823062**

**ABSTRACT**

The feature learning capability using *Convolutional Neural Network* (CNN) has good performance in image segmentation. The architecture of CNN which is often used for image segmentation is *U-Net* and *ResNet* architecture. Several studies have proposed the *Ensemble Learning* (EL) method to combine the results of architectural performance in each image segmentation. *Weighted Voting* is one of the most frequently used EL methods, *Weighted Voting* works by choosing the largest weight from the final prediction generated by each segmentation model. The dataset used is the root image of *Cichorium intybus L* (Chicory) taken from the Zenodo dataset with performance evaluation measures namely accuracy, precision, sensitivity, specificity, F1-Score and Intersection over Union (IoU). The results of this study obtained an accuracy of 99.93%, precision 94.86%, sensitivity 85.19%, specificity 99.98%, F1-Score 89.77%, and IoU 81.44%. Based on these result, it shows that the proposed architecture is able to perform root segmentation in the soil well based on the category of model performance evaluation.

Keywords : *U-Net*, *ResNet*, EL, *Weighted Voting*, Chicory Roots.



**PENERAPAN METODE *ENSEMBLE LEARNING*  
PADA HASIL *U-NET* DAN *RESNET*  
MENGUNAKAN TEKNIK *WEIGHTED VOTING*  
UNTUK SEGMENTASI AKAR PADA TANAH**

Oleh :  
**MUHAMMAD WAHYU ILAHI**  
**NIM. 08011381823062**

**ABSTRAK**

Kemampuan pembelajaran fitur menggunakan *Convolutional Neural Network* (CNN) memiliki kinerja yang baik dalam segmentasi citra. Arsitektur dari CNN yang sering digunakan untuk segmentasi citra adalah arsitektur *U-Net* dan *ResNet*. Beberapa penelitian mengusulkan metode *Ensemble Learning* (EL) untuk menggabungkan hasil kinerja arsitektur pada setiap segmentasi citra. *Weighted Voting* adalah salah satu metode EL yang sering digunakan, *Weighted Voting* bekerja dengan memilih bobot terbesar dari prediksi akhir yang dihasilkan oleh masing-masing model segmentasi. *Dataset* yang digunakan yaitu citra akar *Cichorium intybus L* (Chicory) yang diambil dari dataset Zenodo dengan ukuran evaluasi kinerja yaitu akurasi, presisi, sensitivitas, spesifisitas, *F1-Score*, dan *Intersection over Union* (IoU). Hasil dari penelitian ini memperoleh nilai akurasi 99,93%, presisi 94,86%, sensitivitas 85,19%, spesifisitas 99,98%, *F1-Score* 89,77%, dan IoU 81,44%. Berdasarkan hasil tersebut, menunjukkan bahwa arsitektur yang diusulkan mampu melakukan segmentasi akar pada tanah dengan baik berdasarkan kategori evaluasi kinerja model.

Kata Kunci : *U-Net*, *ResNet*, EL, *Weighted Voting*, Akar Chicory.

## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>ii</b>
<b>HALAMAN PERSEMBAHAN .....</b>	<b>iii</b>
<b>KATA PENGANTAR.....</b>	<b>iv</b>
<b>ABSTRACT .....</b>	<b>vii</b>
<b>ABSTRAK .....</b>	<b>viii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>xi</b>
<b>DAFTAR GAMBAR.....</b>	<b>xii</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Perumusan Masalah.....	4
1.3 Batasan Masalah.....	4
1.4 Tujuan.....	5
1.5 Manfaat.....	5
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>6</b>
2.1 Citra Digital.....	6
2.2 Akar .....	6
2.3 <i>Pre-processing</i> .....	7
2.4 Segmentasi Citra .....	8
2.5 <i>Convolutional Neural Network (CNN)</i> .....	8
2.5.1 <i>Convolutional Layer</i> .....	9
2.5.2 <i>Batch Normalization</i> .....	11
2.5.3 <i>Max Pooling</i> .....	12
2.5.4 <i>Concatenate Layer</i> .....	13
2.5.5 <b>Fungsi Aktivasi</b> .....	13
2.5.6 <i>Loss Function : Binary Cross Entropy</i> .....	14
2.6 <i>U-Net</i> .....	15
2.7 <i>ResNet</i> .....	16
2.8 <i>Ensemble Learning (EL)</i> .....	17
2.9 <i>Confusion Matrix</i> .....	17
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>21</b>
3.1 Tempat.....	21
3.2 Waktu .....	21
3.3 Alat .....	21
3.4 Tahap Penelitian .....	21
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>26</b>
4.1 Deskripsi Data .....	26

4.2	<i>Pre-processing</i>	27
4.3	Operasi Manual pada <i>Convolutional Neural Network</i> (CNN)	28
4.3.1	<i>Padding same</i>	28
4.3.2	<b>Operasi Konvolusi</b>	28
4.3.3	<i>Batch Normalization</i>	30
4.3.4	<i>Max Pooling</i>	33
4.3.5	<i>Concatenate</i>	34
4.3.6	<i>Rectified Linear Unit (ReLU)</i>	35
4.3.7	<i>Sigmoid</i>	35
4.3.8	<i>Tanh</i>	36
4.3.9	<i>Softmax</i>	37
4.3.10	<i>Weighted Voting</i>	38
4.3.11	<i>Binary Cross Entropy</i>	39
4.4	Implementasi Arsitektur	40
4.4.1	<i>U-Net</i>	40
4.4.2	<i>ResNet</i>	45
4.4.3	<i>Ensemble Learning (EL)</i>	49
4.5	Analisis dan Interpretasi Hasil	54
<b>BAB V KESIMPULAN DAN SARAN</b>		<b>55</b>
5.1	Kesimpulan	55
5.2	Saran	55
<b>DAFTAR PUSTAKA</b>		<b>56</b>

## DAFTAR TABEL

Tabel 2.1 <i>Confusion Matrix</i> .....	18
Tabel 2.2 Kategori Evaluasi Kinerja Model .....	19
Tabel 4.1 Data Sampel Citra Akar pada <i>Dataset Zenodo</i> .....	26
Tabel 4.2 Hasil <i>Confusion Matrix</i> yang didapat dari Proses <i>Testing U-Net</i> .....	43
Tabel 4.3 Hasil <i>Confusion Matrix</i> yang didapat dari Proses <i>Testing ResNet</i> .....	47
Tabel 4.4 Hasil <i>Confusion Matrix</i> yang didapat dari Proses <i>Testing EL</i> .....	52
Tabel 4.5 Perbandingan Hasil Segmentasi dari Masing-masing Model .....	54
Tabel 4.6 Perbandingan Hasil Metode dengan Penelitian Lain .....	54

## DAFTAR GAMBAR

Gambar 2.1 Akar Chicory .....	7
Gambar 2.2 Ilustrasi Proses Konvolusi.....	10
Gambar 2.3 Ilustrasi <i>Max Pooling</i> .....	12
Gambar 2.4 Grafik Fungsi Aktivasi.....	14
Gambar 2.5 Arsitektur <i>U-Net</i> .....	15
Gambar 2.6 <i>Residual Block</i> pada Arsitektur <i>ResNet</i> .....	16
Gambar 4.1 Segmentasi Akar pada Tanah.....	27
Gambar 4.2 Hasil <i>Pre-processing</i> .....	27
Gambar 4.3 Proses Mempartisi Matriks <i>Input</i> ke Beberapa Submatriks.....	33
Gambar 4.4 Ilustrasi Proses Penggabungan dengan <i>Concatenate</i> .....	34
Gambar 4.5 Grafik Akurasi Proses <i>Training U-Net</i> .....	41
Gambar 4.6 Grafik <i>Loss</i> Proses <i>Training U-Net</i> .....	41
Gambar 4.7 Perbandingan Hasil Segmentasi dan <i>Ground Truth U-Net</i> .....	42
Gambar 4.8 Grafik Akurasi Proses <i>Training ResNet</i> .....	45
Gambar 4.9 Grafik <i>Loss</i> Proses <i>Training ResNet</i> .....	46
Gambar 4.10 Perbandingan Hasil Segmentasi dan <i>Ground Truth ResNet</i> .....	46
Gambar 4.11 Ilustrasi EL.....	49
Gambar 4.12 Grafik Akurasi Proses <i>Training EL</i> .....	50
Gambar 4.13 Grafik <i>Loss</i> Proses <i>Training EL</i> .....	50
Gambar 4.14 Perbandingan Hasil Segmentasi dan <i>Ground Truth EL</i> .....	51

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

*Machine Learning* (ML) adalah bidang studi yang banyak menggunakan prinsip ilmu komputer dan statistika untuk mengenali pola dari data atau informasi yang terkait dengan permasalahan manusia (Batta, 2020). ML banyak digunakan untuk pekerjaan medis, iklim, menganalisa suatu teks, geofisika, dan lain-lain. Pemanfaatan ML juga banyak digunakan pada segmentasi citra. Segmentasi citra adalah proses pemisahan objek dengan latar belakangnya (Pangaribuan & Simanjuntak, 2021). Segmentasi citra terbagi menjadi dua jenis yaitu segmentasi citra biner dan segmentasi citra semantik. Segmentasi citra saat ini sangat berperan penting dalam berbagai bidang kehidupan dan banyak dilakukan pada citra retina, citra paru-paru, bahkan juga digunakan pada citra akar tanaman (Wu *et al.*, 2019).

Segmentasi citra akar tanaman sangat sulit dilakukan karena bentuk dan warna menyerupai tanah serta ukuran akar yang sangat kecil dan tipis membuat akar menjadi sulit dibedakan (Smith *et al.*, 2020a). Segmentasi akar tanaman berguna untuk mengetahui perkembangan suatu akar. Segmentasi citra akar membantu penelitian atau praktisi pada pertanian untuk dapat mendeteksi kondisi tanaman dari hasil segmentasi. Akar yang tebal, panjang, dan bersih menandakan nutrisi yang cukup, sedangkan akar yang tipis, jarang dan berwarna gelap menandakan kekurangan nutrisi pada tanaman tersebut (Belnap *et al.*, 2016).

Metode yang berkembang pesat pada segmentasi citra adalah *Deep Learning* (DL). DL adalah kumpulan metode yang model pembelajarannya menggunakan *Artificial Neural Network* (ANN) dengan lapisan yang lebih banyak yang mampu mempelajari fitur atau pola dari data yang diberikan secara otomatis dengan baik (Soomro *et al.*, 2019). Metode DL yang sering digunakan untuk segmentasi citra adalah *Convolutional Neural Network* (CNN), karena CNN memiliki kelebihan dalam mengolah *input* data berukuran  $m \times n$  seperti citra (Haque & Neubert, 2020). Arsitektur dari metode CNN yang sering digunakan untuk segmentasi citra adalah arsitektur *U-Net* (Ronneberger *et al.*, 2015).

*U-Net* merupakan arsitektur CNN yang sangat populer karena keakuratannya dalam analisis citra (Du *et al.*, 2020). Bentuk arsitektur U adalah alasan dibalik namanya, huruf U berisi dua jalur yaitu jalur kiri disebut *encoder* dan jalur kanan disebut *decoder* (Hasan & Linte, 2019). Beberapa ukuran evaluasi kinerja segmentasi yang digunakan adalah akurasi, presisi, sensitivitas, spesifisitas, *F1-Score*, dan *Intersection over Union* (IoU). Terdapat beberapa penelitian menerapkan arsitektur *U-Net* yang telah menunjukkan hasil kinerja yang baik diantaranya Smith *et al.* (2020a) menerapkan arsitektur *U-Net* untuk segmentasi akar tanaman menghasilkan nilai akurasi 99,7%, *F1-Score* 70,1% dan sensitivitas 74,8%. Lui *et al.* (2018) menerapkan arsitektur *U-Net* untuk segmentasi citra hewan menghasilkan nilai akurasi 91,98%. Pribadi & Adisusilo. (2020) menerapkan arsitektur *U-Net* untuk gelembung penyebab kanker paru-paru pada lapisan citra *Computerized Tomography Scan* (CT Scan) menghasilkan nilai akurasi 79,8%. Arsitektur *U-Net* memiliki kelemahan pada jumlah lapisan dan parameter yang

banyak sehingga menyebabkan perhitungan komputasi yang berlebihan dan waktu eksekusi yang dibutuhkan selama proses *training* sangat lama (Bi *et al.*, 2017).

Arsitektur yang menggunakan parameter lebih sedikit dan memanfaatkan *skip connection* serta waktu eksekusi yang lebih cepat adalah *ResNet* (Furusho & Ikeda, 2020). Terdapat beberapa penelitian menerapkan arsitektur *ResNet* yang telah menunjukkan hasil kinerja yang baik diantaranya Lin *et al.* (2018) menerapkan arsitektur *ResNet* untuk segmentasi lidah menghasilkan nilai akurasi 98,04% dan IoU 94,30%. Xia *et al.* (2019) menerapkan arsitektur *ResNet* untuk segmentasi citra ginjal menghasilkan nilai IoU 83,1%. Celik *et al.* (2020) menerapkan arsitektur *ResNet* untuk klasifikasi kanker payudara *karsinoma duktal invasif* dengan akurasi 91,96%, sensitivitas 93,64%, spesifisitas 88,28%, dan *F1-Score* 94,11%. Penggunaan *skip connection* pada arsitektur *ResNet* mengakibatkan banyak fitur-fitur yang penting dari lapisan sebelumnya terlewatkan atau hilang sehingga dapat menurunkan kinerja pembelajaran arsitektur (Elswah *et al.*, 2020), berdasarkan kelebihan dan kekurangan dari masing-masing arsitektur, beberapa penelitian mengusulkan menggunakan metode *Ensemble Learning* (EL) untuk mengatasi kekurangan beberapa algoritma (Wang *et al.*, 2017).

EL adalah proses penggabungan nilai *output* dari beberapa model menjadi satu model (Qummar *et al.*, 2019). Teknik *Weighted Voting* adalah salah satu metode EL. *Weighted Voting* bekerja dengan memilih bobot terbesar dari prediksi akhir yang dihasilkan oleh masing-masing model segmentasi maupun klasifikasi (Deppa., Kattimani & Muruli, 2021). Beberapa penelitian sudah banyak menggunakan EL diantaranya Saleh *et al.* (2020) menggunakan *Fuzzy Random*



*Forest* dan *Dominance-Based Rough Set* menghasilkan nilai akurasi 80,05%, spesifisitas 79,58%, dan sensitivitas 81,78%. Antal & Hajdu (2014) menggunakan *Forward* dan *Backward Search* menghasilkan nilai akurasi 87%, dan sensitifitas 90%. Wang *et al.* (2017) melakukan segmentasi pembuluh darah retina menghasilkan akurasi 96,06%, sensitivitas 80,36%, dan spesifisitas 97,83%.

Berdasarkan kelebihan dan kekurangan dari arsitektur serta kemampuan yang dimiliki oleh EL, maka pada penelitian ini akan menerapkan metode EL pada hasil kinerja dari arsitektur *U-Net* dan *ResNet* dengan pengambilan keputusan menggunakan teknik *Weighted Voting*. Hasil evaluasi kinerja model diukur berdasarkan nilai akurasi, presisi, sensitivitas, spesifisitas, *F1-Score*, dan IoU.

## 1.2 Perumusan Masalah

Rumusan masalah dari penelitian ini adalah bagaimana penerapan metode EL menggunakan teknik *Weighted Voting* pada hasil kinerja dari arsitektur *U-Net* dan *ResNet* untuk memperoleh hasil segmentasi akar pada tanah yang lebih akurat berdasarkan ukuran evaluasi kinerja model.

## 1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah :

1. Penelitian ini hanya membahas penerapan metode EL pada hasil *U-Net* dan *ResNet* menggunakan teknik *Weighted Voting* untuk segmentasi akar pada tanah tetapi tidak membahas mengenai proses klasifikasi.
2. Ukuran evaluasi kinerja model pada segmentasi ini menggunakan akurasi, presisi, sensitivitas, spesifisitas, *F1-Score*, IoU.

## 1.4 Tujuan

Tujuan dari penelitian ini adalah menerapkan metode EL pada hasil kinerja dari arsitektur *U-Net* dan *ResNet* menggunakan teknik *Weighted Voting* untuk memperoleh hasil segmentasi akar pada tanah yang lebih akurat berdasarkan ukuran evaluasi kinerja model.

## 1.5 Manfaat

1. Dapat diperoleh metode alternatif pada segmentasi akar pada tanah.
2. Dapat digunakan untuk mengidentifikasi kelainan atau kesuburan suatu tanaman berdasarkan akar yang diperoleh.
3. Dapat digunakan sebagai referensi penelitian terkait segmentasi akar dan sejenisnya.
4. Dapat digunakan untuk proses klasifikasi akar tanaman.

## DAFTAR PUSTAKA

- Alqadi, Z., Khrisat, M., Hindi, A., and Dwairi, M. O. (2020). Features Analysis of RGB Color Image based on Wavelet Packet Information. *International Journal of Computer Science and Mobile Computing*, 9(3), 149-156.
- Antal, B., and Hajdu, A. (2014). An ensemble-based system for automatic screening of diabetic retinopathy. *Knowledge-Based Systems*, 60, 20–27. <https://doi.org/https://doi.org/10.1016/j.knosys.2013.12.023>
- Batta, M. (2020). Machine Learning Algorithms - A Review . *International Journal of Science and Research (IJ)*, 9(1), 381-undefined. <https://doi.org/10.21275/ART20203995>
- Belnap, J., Weber, B., and Büdel, B. (2016). *Biological Soil Crusts as an Organizing Principle in Drylands BT - Biological Soil Crusts: An Organizing Principle in Drylands* (B. Weber, B. Büdel, & J. Belnap (eds.); pp. 3–13). Springer International Publishing. [https://doi.org/10.1007/978-3-319-30214-0\\_1](https://doi.org/10.1007/978-3-319-30214-0_1)
- Bharti, R., Khamparia, A., Shabaz, M., Dhiman, G., Pande, S., and Singh, P. (2021). Prediction of Heart Disease Using a Combination of Machine Learning and Deep Learning. *Computational Intelligence and Neuroscience*, 2021. <https://doi.org/10.1155/2021/8387680>
- Bi, L., Kim, J., Kumar, A., Fulham, M., and Feng, D. (2017). Stacked Fully Convolutional Networks with Multi-Channel Learning: Application to Medical Image Segmentation. *Visual Computer*, 33(6–8), 1061–1071. <https://doi.org/10.1007/s00371-017-1379-4>
- Celik, Y., Talo, M., Yildirim, O., Karabatak, M., and Acharya, U. R. (2020). Automated Invasive Ductal Carcinoma Detection Based Using Deep Transfer Learning with Whole-Slide Images. *Pattern Recognition Letters*, 133, 232–239. <https://doi.org/10.1016/j.patrec.2020.03.011>
- Chen, W., Sun, Q., Wang, J., Dong, J. J., and Xu, C. (2018). A Novel Model Based on AdaBoost and Deep CNN for Vehicle Classification. *IEEE Access*, 6(c), 60445–60455. <https://doi.org/10.1109/ACCESS.2018.2875525>
- Deepa, J., Kattimani, D. R, and Muruli, N. V. (2021). Nutrient Composition of Dehydrated Drumstick Leaves (*Moringa oleifera*) Powder. *International Journal of Current Microbiology and Applied Sciences*, 10(2), 2725–2730. <https://doi.org/10.20546/ijemas.2021.1002.301>
- Desiani, A., Dewi, N. R., Fauza, A. N., Rachmatullah, N., Arhami, M., and

- Nawawi, M. (2021). Handling Missing Data Using Combination of Deletion Technique, Mean, Mode and Artificial Neural Network Imputation for Heart Disease Dataset. *Science and Technology Indonesia*, 6(4), 303–312. <https://doi.org/10.26554/sti.2021.6.4.303-312>
- Ding, B., Qian, H., and Zhou, J. (2018). Activation Functions and Their Characteristics in Deep Neural Networks. *The 30th Chinese Control and Decision Conference (2018 CCDC)*, 1836–1841.
- Du, G., Cao, X., Liang, J., Chen, X., and Zhan, Y. (2020). Medical image segmentation based on U-Net: A review. *Journal of Imaging Science and Technology*, 64(2), 1–12. <https://doi.org/10.2352/J.ImagingSci.Technol.2020.64.2.020508>
- Furusho, Y., and Ikeda, K. (2020). Theoretical analysis of skip connections and batch normalization from generalization and optimization perspectives. *APSIPA Transactions on Signal and Information Processing*, 9. <https://doi.org/10.1017/ATSIP.2020.7>
- Gan, K., Sun, S., Wang, S., and Wei, Y. (2018). A secondary-decomposition-ensemble learning paradigm for forecasting PM2.5 concentration. *Atmospheric Pollution Research*, 9(6), 989–999. <https://doi.org/https://doi.org/10.1016/j.apr.2018.03.008>
- Haque, I. R. I., and Neubert, J. (2020). Deep Learning Approaches to Biomedical Image Segmentation. *Informatics in Medicine Unlocked*, 18, 100297. <https://doi.org/10.1016/j.imu.2020.100297>
- Hasan, S. M. K., and Linte, C. A. (2019). U-NetPlus: A Modified Encoder-Decoder U-Net Architecture for Semantic and Instance Segmentation of Surgical Instruments from Laparoscopic Images. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 7205–7211. <https://doi.org/10.1109/EMBC.2019.8856791>
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Ilse, M., Tomczak, J. M., and Welling, M. (2020). Chapter 22 - Deep multiple instance learning for digital histopathology. In S. K. Zhou, D. Rueckert, & G. B. T.-H. of M. I. C. and C. A. I. Fichtinger (Eds.), *The Elsevier and MICCAI Society Book Series* (pp. 521–546). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-816176-0.00027-2>
- Jin, Z., Fangqiao, H., Weidong, Q., Weida, Z., Yang, X., Yuequan, B., and Hui, L. (2022). A modified U-net for crack segmentation by Self-Attention-Self-

- Adaption neuron and random elastic deformation. *Smart Structures and Systems*, 29(1), 1–16. <https://doi.org/10.12989/SSS.2022.29.1.001>
- Khan, A., Sohail, A., Zahoor, U., and Qureshi, A. S. (2020). A Survey of The Recent Architectures of Deep Convolutional Neural Networks. In *Artificial Intelligence Review* (Vol. 53, Issue 8). Springer Netherlands. <https://doi.org/10.1007/s10462-020-09825-6>
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., and Chen, M. (2014). Medical Image Classification with Convolutional Neural Network. *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, 10–12.
- Lian, S., Li, L., Lian, G., Xiao, X., Luo, Z., and 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>
- Lin, B., Xie, J., Li, C., and Qu, Y. (2018). Deeptongue: Tongue segmentation via resnet. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, 2018-April*, 1035–1039. <https://doi.org/10.1109/ICASSP.2018.8462650>
- Loffe, S., and 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>
- Lui, M. S., Wijaya, E. K., and Hidayat, M. (2018). Segmentasi Citra Hewan dengan Convolutional Neural Network Arsitektur U-Net. *Animal Image Segmentation with Convolutional Neural Network U-Net Architecture*. x(30), 1–5.
- Luque, A., Carrasco, A., Martín, A., and Heras, A. (2019). The Impact of Class Imbalance in Classification Performance Metrics based on The Binary Confusion Matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>
- Mishra, S., Vanli, O. A., Huffer, F. W., and 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(March), 98032H. <https://doi.org/10.1117/12.2217959>
- Pribadi, A., dan Adisusilo, A. K. (2020). Pemanfaatan 3D U-Net untuk Segmentasi 3 Dimensi Gelembung Penyebab Kanker Paru-paru (Nodule) pada Lapisan

- Citra CT Scan. *Journal of Intelligent System and Computation*, 2(2), 74–85.  
<https://doi.org/10.52985/insyst.v2i2.159>
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., Khan, I. A., and Jadoon, W. (2019). A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection. *IEEE Access*, 7, 150530–150539.  
<https://doi.org/10.1109/ACCESS.2019.2947484>
- Romera, E., Bergasa, L. M., Alvarez, J. M., and Trivedi, M. (2018). Train Here, Deploy There: Robust Segmentation in Unseen Domains. *IEEE Intelligent Vehicles Symposium, Proceedings, 2018-June(Iv)*, 1828–1833.  
<https://doi.org/10.1109/IVS.2018.8500561>
- Ronneberger, O., Fischer, P., and 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, 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Sakinah, N., Tahir, M., Badriyah, T., and Syarif, I. (2019). LSTM With Adam Optimization-Powered High Accuracy Preeclampsia Classification. *2019 International Electronics Symposium (IES)*, 314–319.  
<https://doi.org/10.1109/ELECSYM.2019.8901536>
- Saleh, A., Yuzir, A., and Abustan, I. (2020). Flash Flood Susceptibility Modelling: A Review. *IOP Conference Series: Materials Science and Engineering*, 712(1). <https://doi.org/10.1088/1757-899X/712/1/012005>
- Shi, J., Dang, J., Cui, M., Zuo, R., Shimizu, K., Tsunoda, A., and Suzuki, Y. (2021). Improvement of Damage Segmentation Based on Pixel-Level Data Balance Using VGG-Unet. *Applied Sciences (Switzerland)*, 11(2), 1–17.  
<https://doi.org/10.3390/app11020518>
- Smith, A. G., Petersen, J., Selvan, R., and Rasmussen, C. R. (2020a). Segmentation of roots in soil with U-Net. *Plant Methods*, 16(1), 1–13.  
<https://doi.org/10.1186/s13007-020-0563-0>
- Smith, A. G., Han, E., Petersen, J., Olsen, N. A. F., Giese, C., Athmann, M., Dresboll, D. B., and Kristensen, K. T.. (2020). RootPainter: Deep Learning Segmentation of Biological Images with Corrective Annotation. *BioRxiv Plant Biology*, 1–16.
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., and 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>

- Soomro, T. A., Zheng, L., Afifi, A. J., Ali, A., Yin, M., and Gao, J. (2022). Artificial intelligence (AI) for medical imaging to combat coronavirus disease (COVID-19): a detailed review with direction for future research. In *Artificial Intelligence Review* (Vol. 55, Issue 2). Springer Netherlands. <https://doi.org/10.1007/s10462-021-09985-z>
- Stráský, J., Janeček, M., Harcuba, P., Preisler, D., and Landa, M. (2018). 4.2 - Biocompatible beta-Ti alloys with enhanced strength due to increased oxygen content. In F. H. Froes & M. B. T.-T. in M. and D. A. Qian (Eds.), *Woodhead Publishing Series in Biomaterials* (pp. 371–392). Woodhead Publishing. <https://doi.org/https://doi.org/10.1016/B978-0-12-812456-7.00017-2>
- Wang, S. H., Tang, C., Sun, J., Yang, J., Huang, C., Phillips, P., and 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>
- Wu, C., Zou, Y., and 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), 1–7. <https://doi.org/10.1088/1757-899X/533/1/012053>
- Xia, K., Yin, H., and Zhang, Y. (2019). Deep Semantic Segmentation of Kidney and Space-Occupying Lesion Area Based on SCNN and ResNet Models Combined with SIFT-Flow Algorithm. *Journal of Medical Systems*, 43(1), 1–12. <https://doi.org/10.1007/s10916-018-1116-1>
- Yamashita, R., Nishio, M., Do, R. K. G., and Togashi, K. (2018). Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition. *Insights into Imaging*, 9(4), 21–30. [https://doi.org/10.1007/978-981-15-7078-0\\_3](https://doi.org/10.1007/978-981-15-7078-0_3)
- Yin, R., Luo, Z., Zhuang, P., Lin, Z., and Kwoh, C. K. (2021). VirPreNet: A weighted ensemble convolutional neural network for the virulence prediction of influenza A virus using all eight segments. *Bioinformatics*, 37(6), 737–743. <https://doi.org/10.1093/bioinformatics/btaa901>
- Zhang, Z., Liu, Q., and Wang, Y. (2018). Road Extraction by Deep Residual U-Net. *IEEE Geoscience and Remote Sensing Letters*, 15(5), 749–753. <https://doi.org/10.1109/LGRS.2018.2802944>
- Zhao, G., Liu, G., Fang, L., Tu, B., and Ghamisi, P. (2019). Multiple Convolutional Layers Fusion Framework for Hyperspectral Image Classification. *Neurocomputing*, 339, 149–160. <https://doi.org/10.1016/j.neucom.2019.02.019>