



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 1 (2026) pp: 7097-7109

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Perangkat Cerdas Berbasis U-Net untuk Memantau Kerusakan Daun Pakcoy Akibat Serangan Hama

Ni Komang Diani^{1*}, Made Windu Antara Kesiman², I Made Gede Sunarya³, Putu Zasya Eka Satya Nugraha⁴

^{1,2,3}Pendidikan Teknik Informatika, Universitas Pendidikan Ganesha, Indonesia

⁴PT Dago Engineering, Indonesia

¹diani.2@student.undiksha.ac.id, ²antara.kesiman@undiksha.ac.id, ³sunarya@undiksha.ac.id, ⁴zasya@dagoeng.co.id

Abstrak

Implementasi Pertanian modern di Smart Green Garden Universitas Pendidikan Ganesha saat ini menghadapi tantangan yang signifikan dalam efisiensi mendeteksi serangan hama pada tanaman Pakcoy (*Brassica rapa L.*). metode pemantauan secara manual terbukti tidak efektif dan memakan waktu yang cukup lama serta mengalami kesulitan dalam mengenali kerusakan daun pakcoy dalam skala besar. Penelitian ini berfokus pada pengembangan perangkat cerdas yang menggabungkan arsitektur deep learning U-Net untuk segmentasi semantik dengan perangkat Internet of Things (IoT). Sistem ini menggunakan kamera CCTV yang dimodifikasi dengan Stepper motor Nema 23 dan Arduino Nano untuk melakukan pemindaian area tanam secara otomatis dalam radius 360 derajat secara otomatis. Dataset penelitian berjumlah 405 citra hasil augmentasi berkualitas tinggi dengan resolusi 512x512 piksel untuk memperkuat generalisasi model. Model U-Net dilatih menggunakan strategi 5-fold cross validation. Hasil evaluasi menunjukkan bahwa Model U-Net pada (Fold-2) menghasilkan performa paling unggul dengan tingkat Akurasi Global 96,8% dan Mean Intersection over Union (mIoU) sebesar 0,683. Sistem ini mampu mendeteksi serta memvisualisasikan area kerusakan daun, seperti lubang dan bercak, secara real-time melalui koneksi Real-Time Streaming Protocol (RTSP) pada dashboard website, hal ini menjadi alternatif pemantauan yang lebih presisi dibandingkan metode deteksi objek konvensional untuk deteksi dini serangan hama. Sehingga sistem cerdas ini diharapkan mampu membantu petani untuk efisiensi waktu pemantauan.

Kata kunci: Deep Learning, U-Net, Smart Farming, IoT, Segmentasi Semantik.

1. Latar Belakang

Kolaborasi antara Universitas Pendidikan Ganesha dan PT Dago Engineering telah mengembangkan *Smart Green Garden (SGG)* sebagai wadah laboratorium untuk implementasi teknologi pertanian cerdas (*Smart Farming*). Di *Smart Green Garden* tanaman pakcoy (*Brassica rapa L.*) menjadi komoditas utama yang dikelola dengan sistem hidroponik [1]. Walaupun penggunaan lahan menjadi lebih efisien, pengelola kebun masih dihadapkan pada hambatan serangan hama yang merusak kualitas fisik daun tanaman [2]. Merujuk pada temuan dilokasi, menunjukkan bahwa pemantauan dilakukan dengan mekanisme konvensional, petani wajib untuk mengecek tanaman pakcoy satu per satu. Mekanisme semacam ini menyita waktu dan juga beresiko tinggi dalam mengalami kesalahan pada manusia (*human error*). Oleh karena itu, dibutuhkan sebuah solusi teknologi pemantauan otomatis berbasis kecerdasan buatan (*artificial intelligence*) untuk mengoptimalkan proses pemantauan [3].

Pemanfaatan teknologi *deep learning* dalam ranah pengolahan citra digital sebetulnya telah teruji efektivitasnya di berbagai sektor. Sebagai contoh, di bidang medis, arsitektur *Convolutional Neural Network (CNN)* sukses digunakan untuk mengidentifikasi penyakit *pneumonia* melalui foto *X-ray* [4]. Di sisi lain, teknologi visi komputer dapat berperan dalam pelestarian warisan budaya, seperti riset yang dilakukan oleh Kesiman dan Maysanjaya untuk mengenali karakter pada naskah lontar Bali [5]. Dari rangkaian studi tersebut membuktikan kemampuan algoritma cerdas dalam meniru ketelitian mata manusia untuk mengenali pola yang rumit.

Implementasi arsitektur *deep learning* membuktikan keandalan algoritma YOLOv11 dalam melakukan estimasi objek yang bersifat utuh, seperti pada penghitungan buah kelapa [6]. Namun, mekanisme tersebut biasanya hanya berfungsi untuk menciptakan kotak pembatas (*bounding box*) pada posisi objek yang terdeteksi. Akan tetapi metode ini efektif untuk deteksi objek masif, penggunaan *bounding box* dinilai kurang kompeten dalam

memetakan bentuk kerusakan daun pakcoy yang tidak beraturan (asimetris) secara presisi. Oleh sebab itu, diperlukan untuk mengadopsi teknologi yang mampu bekerja hingga taraf piksel guna mendapatkan detail kerusakan yang lebih mendalam [7]. Ketajaman metode segmentasi ini sudah dibuktikan. Dengan arsitektur U-Net untuk memisahkan *hard exudate* [8] dan *soft exudate* [9] pada citra retina mata. Selain itu metode U-Net berhasil dalam melakukan segmentasi area pematang sawah [10]. Berdasarkan rekam jejak yang telah dijabarkan, penelitian ini menerapkan arsitektur U-Net dalam menangani area kerusakan daun pakcoy dengan akurasi lebih tinggi.

Selain aspek ketajaman algoritma, luasnya jangkauan observasi juga menjadi poin yang sangat krusial. Penggunaan kamera statis sering kali terkendala oleh sudut pandang yang terbatas (*blind spot*), sehingga ada bagian tanaman yang luput dari pengawasan [11]. Salah satu jalan keluar yang dapat ditempuh adalah mengombinasikan sistem visi komputer dengan mekanisme perangkat keras yang bersifat dinamis. Konsep ini selaras dengan pengembangan robot berbasis *Internet of Things (IoT)*, di mana kendali *mikrokontroler* dimanfaatkan untuk mengatur pergerakan komponen mekanik secara otomatis [12].


Menanggapi tantangan ini, penelitian ini mengusulkan pengembangan sebuah perangkat cerdas yang terintegrasi dengan arsitektur U-Net untuk segmentasi area daun rusak dengan sistem kamera yang bergerak secara otomatis. Integrasi ini dapat diharapkan untuk menghadirkan sistem pemantauan di SGG dengan menyeluruh, teliti, dan efisien. Riset ini diinisiasi untuk memberikan kontribusi nyata pada: (1) pembuatan dataset citra kerusakan daun yang diambil langsung menggunakan cctv di lapangan; (2) pembuatan sistem pemantauan yang dipadukan dengan CCTV bergerak secara otomatis dengan didukung protokol RTSP untuk mengatasi keterbatasan sudut pandang; (3) studi komparatif untuk *hyperparameter* arsitektur U-Net untuk mendapatkan model segmentasi yang terbaik; (4) evaluasi kinerja sistem secara total pada kondisi nyata di lingkungan *Smart Green Garden* FTK Universitas Pendidikan Ganesha

2. Metode Penelitian

Pelaksanaan penelitian ini memadukan kerangka kerja *Research and Development (R&D)* dengan pendekatan sistematis yang dirancang khusus untuk pengembangan teknologi cerdas [13]. Rangkaian proses penelitian ini mencakup lima tahapan utama mulai dari pengembangan perangkat keras hingga skenario pengujian. Tahap pertama dimulai dengan proses perancangan perangkat keras (*hardware*), dataset dan prapemrosesan data, pengembangan model U-Net, integrasi perangkat keras dan model U-Net, serta peneliti melakukan skenario pengujian

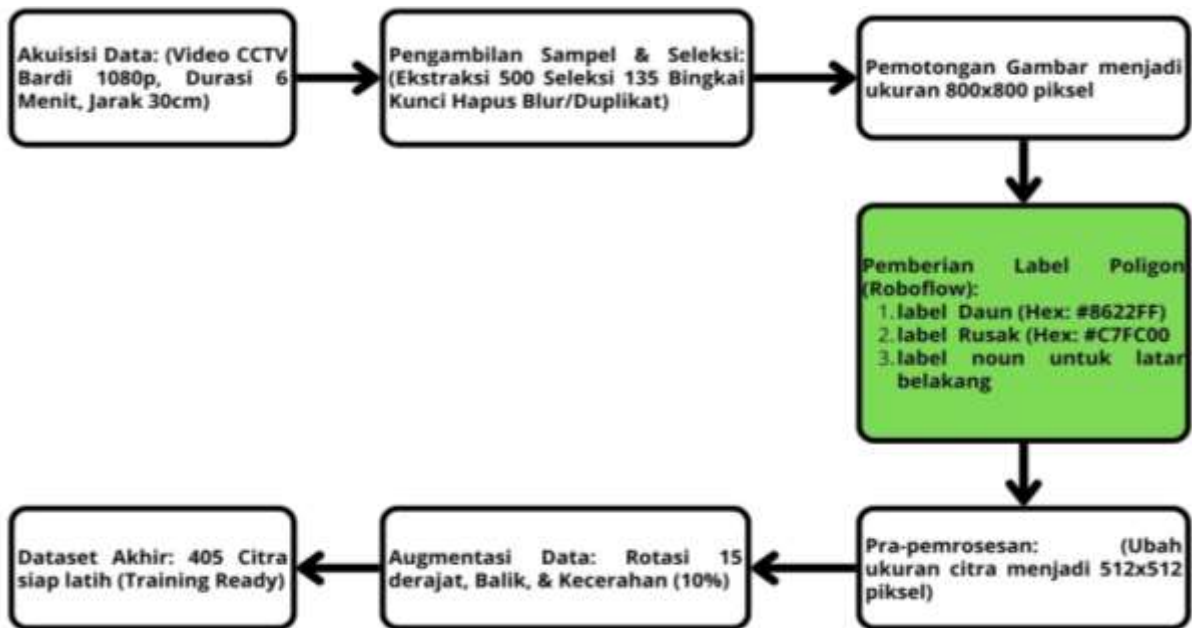
2.1. Perancangan Perangkat Keras (*Hardware*)

Arsitektur sistem cerdas pada penelitian ini menggabungkan dua elemen fundamental, yaitu perangkat keras (*hardware*) dan sistem manajemen data perangkat lunak (*software*). Fokus pengembangan pada sisi perangkat keras meliputi pada perakitan mekanisme gerak kamera yang aktif untuk pemantauan yang luas. Unit kamera CCTV Bardi dipadukan dengan *stepper motor* Nema 23 dan *driver motor stepper* yang diatur melalui mikrokontroler Arduino Nano. Dari konfigurasi tersebut bertujuan untuk memberikan kemampuan rotasi 360 derajat searah jarum jam selama 3 menit dan berlawanan arah selama 3 menit pada kamera, rotasi dilakukan searah jarum jam dan berlawanan dilakukan untuk memastikan sudut kamera bervariasi. Maka dari itu, masalah terhadap sudut pandang kamera yang ditemukan di *Smart Green Garden* dapat dieliminasi secara optimal. Pada Gambar 1. Integrasi antara sensor, aktuator, dan mikrokontroler ini mengacu pada prinsip sistem robotik berbasis IoT [11], yang menekankan stabilitas kendali mekanik untuk mendapatkan input data yang konsisten.



Gambar 1. Wiring IoT dan Rancangan Penempatan Kamera

2.2. Dataset dan Prapemrosesan Data



Gambar 2. Alur persiapan dataset.

Pada penelitian ini proses penyiapan dataset dilakukan dengan beberapa tahapan, mulai dari akuisisi citra hingga augmentasi data. Sesuai alur yang di ilustrasikan pada Gambar 2. Data diambil berupa data video dengan durasi 6 menit yang di ambil secara mandiri menggunakan CCTV Bardi dengan jarak 30 cm dari atas tanaman pakcoy. Pengambilan data dilakukan ketika pagi, siang, dan sore hari, hal ini dilakukan untuk menjamin ketangguhan model terhadap variasi pencahayaan. Dari total 500 frame diawal, seleksi ketat dilakukan untuk mengeliminasi citra yang blur, duplikat, dan citra yang tidak sesuai target seperti citra pipa yang tidak terdapat tanaman pakcoy. Maka, dihasilkan 135 *key frame* representatif dari resolusi awal 2304x1296 piksel dan dilakukan proses pemotongan gambar menjadi 800x800 piksel. Pemotongan gambar dilakukan agar tidak pecah dan gepeng. Proses pelabelan dilakukan pada platform Roboflow dengan menggunakan *Polygon Masking* yang berfungsi untuk

DOI: <https://doi.org/10.31004/riggs.v5i1.6957>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

memetakan area kerusakan daun secara tepat dan presisi. Pelabelan (*Labelling*) dilakukan dengan dua kategori yaitu kelas daun yang diberi warna *vivid violet* dan kelas area daun rusak dengan warna *electric lime*, sampel data *labelling* dapat dilihat pada Gambar 3. Kemudian citra melalui pra-pemrosesan yaitu dilakukan *resize* menjadi ukuran 512x512 piksel. Hal ini dilakukan agar tidak membebani kerja GPU dibandingkan dengan menggunakan ukuran asli. Selain itu, dilakukan augmentasi untuk mencegah overfitting dengan penerapan rotasi kurang lebih 15 derajat, *flip*, dan dicerahkan 10%, diredupkan -10%. Sehingga data yang didapatkan menjadi 405 citra yang siap digunakan ketahap pelatihan model.



Gambar 3. Sampel Dataset Asli dan Hasil Labelling Manual Roboflow.

2.3. Pengembangan Model U-Net


Arsitektur U-Net diterapkan pada penelitian ini sebagai basis model, yang diperkenalkan oleh Ronneberger pada tahun 2015. Tetapi, terdapat pendekatan yang berbeda dengan desain asli yang menggunakan input *grayscale* untuk citra mikroskopi [14], penelitian ini melakukan penyesuaian input citra menjadi 512x512x3 piksel (RGB) untuk menangani area daun rusak yang disebabkan oleh hama, sejalan dengan pendekatan adaptasi kanal warna pada studi segmentasi modern [15]. Penyesuaian dengan menggunakan 3 kanal warna (RGB) dilakukan agar model mampu mengekstrak fitur daun secara spesifik.

Struktur jaringan difungsikan untuk menjaga keutuhan simetri jalur kontraksi (*encoder*) dan ekspansi (*decoder*), di mana fitur spasial yang hilang selama proses *downsampling* (menggunakan *max pooling*) dibangun ulang melalui mekanisme *Skip Connections*. Hal ini sangat penting untuk mempertahankan detail tepian (*boundary*) area rusak daun yang beragam rupa agar tidak kabur saat rekonstruksi resolusi tinggi di lapisan output, dengan diakhiri operasi konvolusi 1x1 dalam memetakan prediksi tigas kelas (latar belakang, daun, area daun rusak).

Untuk menjaga stabilitas konvergensi pada *landscape loss* yang kompleks, penelitian ini mengatur *Learning Rate* (LR) sebesar = (0,0001) menggunakan *optimizer Adam*. Nilai LR konservatif ini dipilih untuk meredam *overshooting gradien* yang sering terjadi pada model dengan arsitektur *deep*. Kendala memori GPU (*Out of Memory*) pada resolusi 512x512 ditangani dengan menetapkan mini-batch size sebesar 8, yang menyelaraskan efisiensi komputasi dan stabilitas *update* bobot. Validitas model diuji menggunakan skema 5-fold cross validation dengan *early stopping* (*patience=7*), meyakinkan bahwa performa model yang dilaporkan adalah hasil generalisasi yang robust terhadap variasi data latih, bukan hasil *overfitting* pada satu subset data tertentu.

Kendala utama pada *dataset* ini adalah *high class imbalance*, di mana piksel penyakit (kelas minoritas) jauh lebih sedikit dibandingkan latar belakang. Penggunaan *cross entropy* tunggal berpotensi besar membuat model bias ke kelas mayoritas. Oleh karena itu, penelitian ini menerapkan skema fungsi kerugian hibrida. *Categorical cross*

entropy berperan dalam memaksimalkan probabilitas klasifikasi per piksel, sementara *dice loss* difokuskan untuk mengoptimalkan irisan (*intersection*) area prediksi. Kombinasi ini secara matematis mengharuskan model untuk sensitif terhadap objek penyakit berukuran kecil yang sering dikesampingkan, hal ini dapat meningkatkan skor *IoU* dan *F1-Score* secara drastis dibandingkan penggunaan *loss function* tunggal. sehingga batas area kerusakan daun dapat diprediksi dengan sangat presisi [16]. Efektivitas mekanisme ini dalam menangani detail objek mikro telah divalidasi pada penelitian segmentasi medis [17], serta terbukti tangguh untuk segmentasi objek lingkungan pertanian [18]. (Gambar arsitektur dapat dilihat pada Gambar 4).



Gambar 4. Arsitektur Modifikasi U-Net yang diusulkan.

Model menerima input citra RGB 512x512x3 dan menghasilkan peta segmentasi dengan resolusi spasial yang sama untuk 3 kelas *output*. Panah abu-abu menunjukkan *skip connections* yang mentransfer fitur detail dari encoder ke decoder.

2.4. Integrasi Perangkat Keras dan Model U-Net

Integrasi sistem dalam penelitian ini menggabungkan tata kerja kontrol perangkat keras dan pengolahan citra berorientasi pada *deep learning* dalam satu arsitektur jaringan terintegrasi penuh. Perangkat keras utama berupa CCTV Bardi Smart IP Cam yang dikonfigurasi dengan Arduino Nano dan *stepper motor* Nema 23 difungsikan melakukan akuisisi data visual tanaman secara langsung dan meneruskan ke VPS (*Virtual Private Server*) melalui protokol RTSP (*Real-Time Streaming Protocol*). Di sisi server aliran video tersebut di proses menjadi *frame* gambar oleh skrip Python dan dikirimkan ke FastAPI, sebuah *framework* berkinerja tinggi yang digunakan sebagai *Inference Server* untuk mengolah model U-Net guna memprediksi dan mensegmentasi area kerusakan daun secara mandiri tanpa intervensi manual. Hasil prediksi berupa gambar hasil segmentasi kemudian diunggah kembali ke dalam direktori statis di VPS, yang setelah itu dipanggil dan disajikan secara rutin oleh antarmuka *website* agar petani dapat melakukan monitoring status kesehatan tanaman hidroponik dari jarak jauh tanpa hambatan waktu dan lokasi.

2.5 Skenario Pengujian

Model U-Net dilakukan Pengujian untuk mengetahui seberapa baik model, dalam penelitian ini menggunakan teknik *k-fold cross validation* dengan $k=5$. Pada pelatihan akan diulang sebanyak 5 kali, yang dilakukan secara bergantian. Pada setiap perulangan salah satu *fold* secara bergantian menjadi data validasi, sementara empat *fold* lainnya digabungkan menjadi data *training*. Sehingga seluruh data bagian pada akhirnya pernah dievaluasi sebagai data validasi. Pada setiap sesi latihan *hyperparameter* diatur dengan 50 *epoch*, *batch size* 8, kecepatan belajar (*learning rate*) 0,0001 dan *optimizer* Adam. Jika dalam 7 *epoch* nilai *error*-nya tidak mengalami penurunan, latihan otomatis berhenti (*early stopping*) untuk mencegah *overfitting*. Kinerja segmentasi kualitas model ditulis dengan *IoU*, *F1-Score*, *Accuracy*.

3. Hasil dan Diskusi

3.1. Evaluasi Kinerja Model U-Net

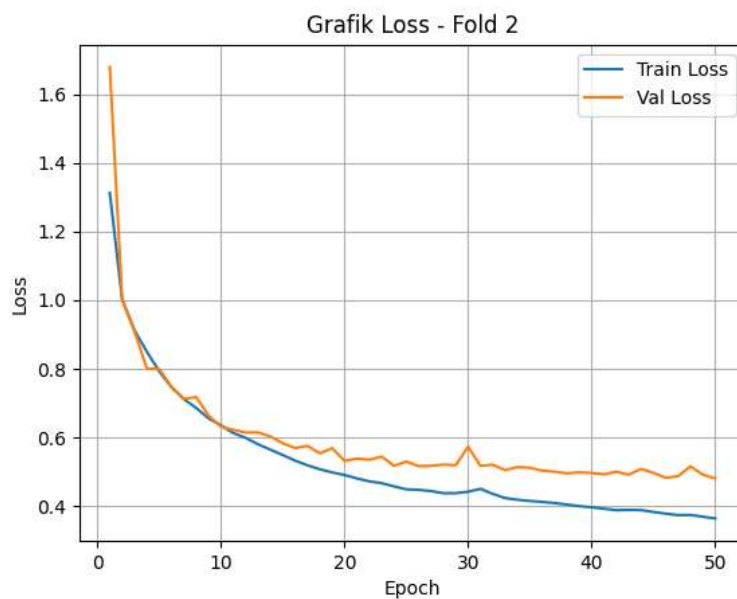
Evaluasi pada model dilakukan dengan komprehensif menggunakan metode *5-fold cross validation* untuk memastikan validitas model pada variasi data *training* dan data uji. pelatihan setiap *fold* di proses selama 50 *epoch* dengan mekanisme *early stopping* (*patience*=7) yang berfungsi untuk mencegah *overfitting*.

Tabel 1. Rekapitulasi Hasil Evaluasi Model U-Net (5 Fold)

| Fold | Accuracy | Loss Terendah | MIoU | Keterangan |
|------|----------|---------------|-------|-------------------------------|
| 1 | 96.3% | 0.385 | 0.652 | Early Stop Ep 40 |
| 2 | 96.8% | 0.364 | 0.683 | Model Terbaik |
| 3 | 97.1% | 0.366 | 0.670 | Stabil namun IoU lebih rendah |
| 4 | 96.3% | 0.358 | 0.657 | Performa Baik |
| 5 | 96.7% | 0.347 | 0.670 | Performa Baik |

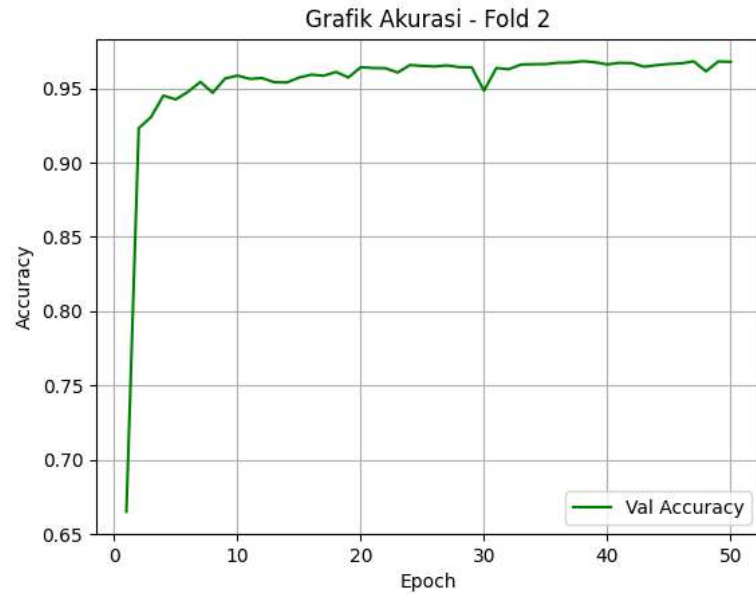
Berdasarkan tabel 1, Fold-2 memiliki kinerja tertinggi dengan *mean intersection over union* (mIoU) sebesar 0.683 dan akurasi 96.8%. Nilai mIoU diatas 0.60 pada kasus segmentasi objek kecil (area spot daun rusak) dikategorikan baik, meskipun model Fold-3 memiliki akurasi lebih tinggi, namun Fold-3 memiliki nilai IoU 0.670 lebih rendah dari Fold-2. Didalam segmentasi semantik untuk objek kecil, metrik IoU diprioritaskan untuk ketepatan bentuk area daun rusak dibandingkan dengan akurasi pixel pada latar belakang. oleh karena itu, bobot model (*weight*) dari Fold-2 digunakan untuk implementasi sistem *real-time*.

3.1.1 Analisis Grafik Pelatihan Fold-2



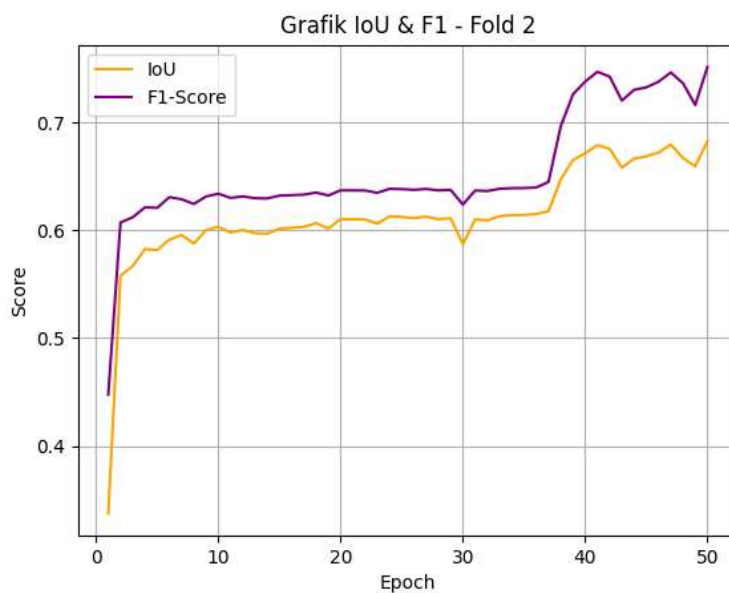
Gambar 5. Grafik Perubahan Training dan Validation Loss pada Fold-2.

Pada Gambar 5 menunjukkan kurva Loss mengalami penurunan drastis pada epoch 10 pertama, yang menunjukkan bahwa model belajar fitur visual dengan cepat. Grafik mulai stabil pada *epoch* 40 hingga *epoch* 50, dengan nilai *validation loss* terendah di angka 0.364. Garis *training* warna biru dan *validation* warna orange dengan jarak sempit hal ini mengindikasikan model memiliki generalisasi baik dan tidak mengalami *overfitting*.



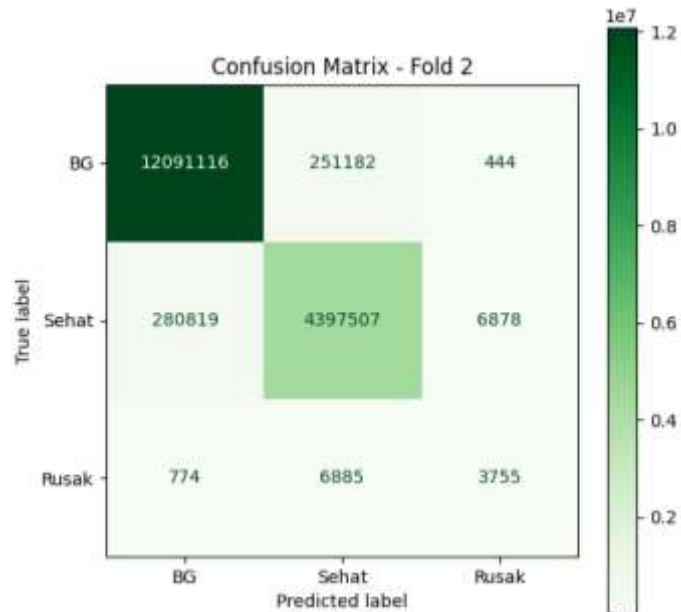
Gambar 6. Grafik Perubahan Accuracy pada Fold-2.

Pada Gambar 6 menunjukkan bahwa tren peningkatan akurasi yang stabil sejalan dengan bertambahnya iterasi *training*. Tingkat akurasi validasi mencapai 96.8%. Keseimbangan grafik pada *epoch* akhir menandakan bahwa model telah berhasil mendeteksi pola piksel daun dan *background* dengan tingkat kepercayaan tinggi.



Gambar 7. Grafik Perubahan IoU dan F1-Score Fold-2

Pada Gambar 7 memperlihatkan performa segmentasi yang spesifik. Melalui proses *training* nilai mIoU mencapai angka 0.683. selain itu nilai dari F1-Score mencapai 0.811 yang membuktikan keselarasan model antara presisi dan sensitivitas pada mendeteksi area daun rusak yang memiliki bentuk tidak beraturan.



Gambar 8. Confusion Matrix

Pada Gambar 8 menunjukkan visualisasi Confusion Matrix dengan detail prediksi sekitar 17 Juta pixel validasi. Rincian analisis matriks sebagai berikut: (1) Kelas Latar Belakang: Pada warna hijau tua nilai diagonal utama yang mendominasi menunjukkan prediksi yang tepat, pada kotak kiri atas dengan jumlah piksel 12.091.116 model mendeteksi latar belakang benar (*true positive background*), pada kotak tengah atas dengan nilai 251.182 piksel model menebak di latar belakang terdapat daun (*false positive daun*) artinya di pipa atau tanah ada kotoran atau rumput liar yang ditebak daun oleh model. Pada kotak kanan atas dengan nilai 444 piksel model menebak terdapat area daun rusak di latar belakang (*false positive rusak*) namun jumlah ini sangat sedikit dari 12 juta piksel sehingga eror ini bisa diabaikan. (2) Kelas Daun: Pada kotak tengah kiri dengan jumlah nilai piksel 280.819 model menemukan kesalahan kecil pada kelas daun yang di deteksi sebagai latar belakang (*false negative daun*) Hal ini diakibatkan pada bagian ujung daun yang tipis dan runcing. Pada kotak tengah dengan jumlah nilai piksel 4.397.507 model mendeteksi daun (*true positive daun*) artinya model berhasil mengenali area hijau daun dengan baik. (3) Kelas Area Daun Rusak: Kotak kanan tengah dengan jumlah nilai 6.878 piksel model mendeteksi daun sebagai area daun rusak (*false positive rusak*). Pada kotak kiri bawah dengan nilai 774 piksel model mendeteksi latar belakang di area daun rusak (*missed detection*). Artinya terdapat lubang pada daun yang terlewat total, dianggap pipa/ atau tanah. Pada kotak tengah bawah dengan nilai jumlah piksel 6.885 model mendeteksi area daun rusak dianggap daun (*false negative*). Ini biasanya diakibatkan oleh kecilnya gradasi warna pada batas antara lubang yang disebabkan oleh hama dan jaringan daun. Pada kotak bawah model berhasil mendeteksi 3.755 piksel area daun rusak secara akurat (*true positive*).

Pada hasil evaluasi *confusion matrix* peneliti melakukan visual perbandingan pada sampel citra yang mengalami kegagalan segmentasi dengan tujuan untuk identifikasi penyebab utama kegagalan model dalam membedakan kelas secara presisi pada kondisi nyata di lapangan hasil pengamatan dapat dilihat pada Gambar 9.



Gambar 9. Visualisasi perbandingan misklasifikasi.

Berdasarkan perbandingan visual pada Gambar 9, disimpulkan bahwa mayoritas kegagalan segmentasi terjadi akibat bias visual intensitas piksel pada fisik objek dan bukan murni kegagalan ekstraksi fitur oleh arsitektur U-Net. Pada area dengan tanda oval merah adalah kelas area daun rusak yang diprediksi latar belakang (*missed detection*). ini merepresentasikan 774 piksel kesalahan pada *confusion matrix*. Alasan ini terjadi karena area daun rusak tajam tembus pandang, sehingga CCTV menangkap gambar tanah atau pipa PVC di belakangnya. Sementara itu, pada area yang ditandai dengan oval biru model gagal mengenali area daun rusak dan menganggapnya daun, yang mempresentasikan pada 6.885 piksel kesalahan (*false negative*). kesalahan ini terjadi karena area lubang berukuran kecil atau transisi gradasi lubang samar dan masih didominasi pigmen hijau.

Selanjutnya, area yang ditandai oval warna kuning model gagal memprediksi daun dan menganggapnya latar belakang, total kesalahan mencapai 280.819 piksel (*false negative* daun). Hal ini terjadi karena bagian ujung daun yang melengkung menjauhi titik fokus lensa atau blur dan tertutup bayangan tajam (gelap atau terang) sehingga kehilangan beberapa fitur ketajaman tepi nilai RGB menurun. Dan pada oval warna ungu terjadi ketidaknormalan pada latar belakang diklasifikasikan sebagai daun (*false positive*) sebanyak 251.182 piksel. Kesalahan prediksi ini terjadi transisi warna latar belakang didominasi pigmen hijau, sehingga bias visual semantik ini mengecoh model saat proses inferensi.

3.2 Hasil Implementasi dan pengujian sistem IoT

Setelah dilakukan validasi model U-Net terbaik (Fold-2), langkah selanjutnya adalah mengimplementasikan model ke dalam arsitektur sistem pemantauan berbasis *Internet Of Things* (IoT). Pada pengujian ini fokus terhadap perangkat keras di lokasi dan kinerja pemrosesan waktu ketika sistem di jalankan di *Virtual Private Server* (VPS).

3.2.1. Pengujian Perangkat Keras dan Transmisi Data

Mekanisme cerdas yang dikembangkan telah berhasil diimplementasikan di lingkungan *Smart Green Garden*. Pengujian fungsional menunjukkan bahwa integrasi antara lengan kamera bergerak dan antarmuka web berjalan sesuai rancangan. Mekanisme *Finite State Machine* (FSM) pada mikrokontroler Arduino Nano sukses mengendalikan *stepper motor* untuk memutar kamera CCTV 360 derajat, memastikan seluruh area tanaman pakcoy terpindai tanpa *blind spot*, perangkat ditunjukkan pada Gambar 10.



Gambar 10. Implementasi Penempatan Kamera dan rangkaian IoT

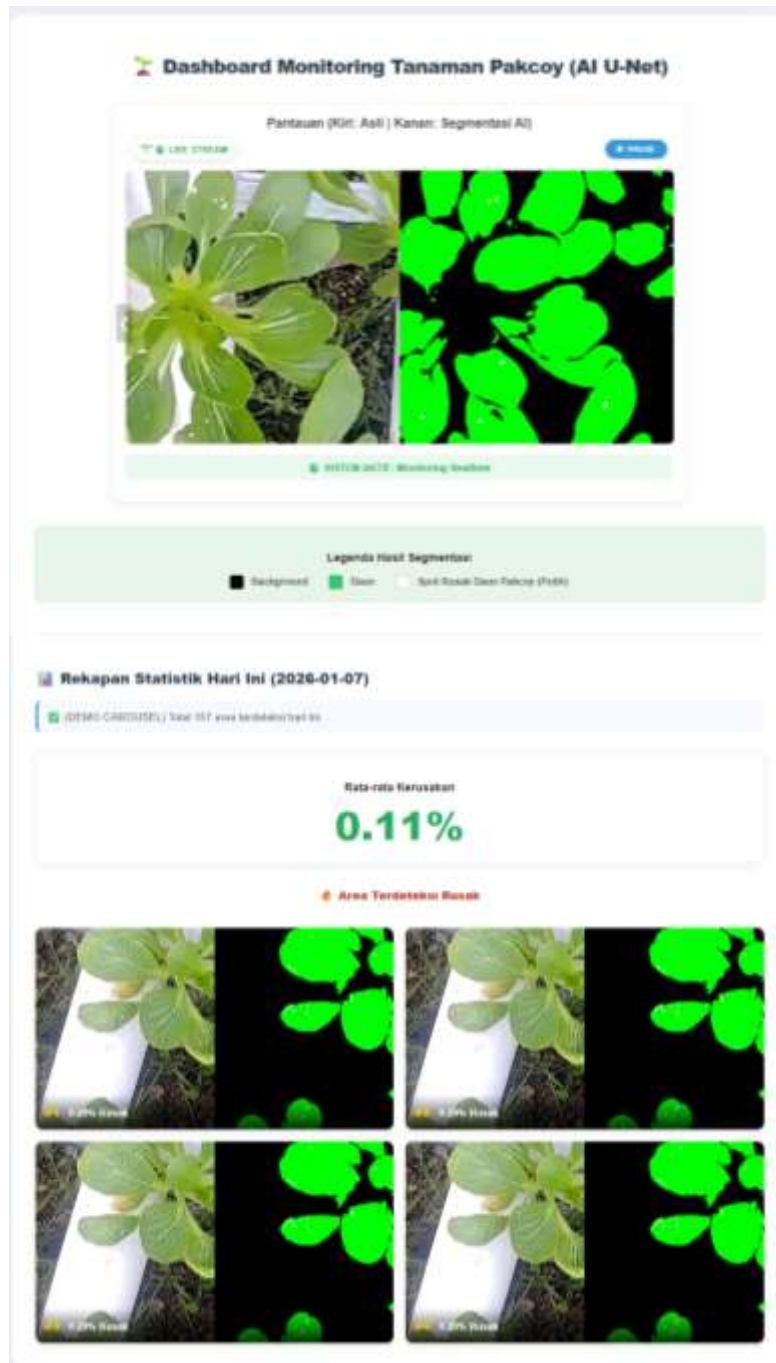
Terfokus pada transmisi data visual, sistem ini memanfaatkan protos RTSP (*Real Time Streaming Protocol*). Berdasarkan hasil implementasi di *Smart Green Garden*, transfer data video dengan resolusi tinggi dari CCTV berhasil terkirim ke VPS secara stabil dengan latensi rata rata sebesar 2 detik. Stabilitas dan kecepatan ini tergantung pada kualitas *bandwidth* internet di *Smart Green Garden*.

3.2.2. Kinerja Inference Server (FastAPI)

Pada proses pengolahan citra dilakukan secara terpusat dengan menggunakan *framework* FastAPI di dalam VPS. Bobot (*weights*) dari model U-Net Fold-2 di unggah ke memori *server*. Hal ini dilakukan agar sistem bisa menjalankan deteksi secara mandiri pada setiap *frame* baru. Berdasarkan pengujian integrasi, aliran *frame* dari RTSP hingga proses prediksi berfungsi tanpa kendala. FastAPI sukses memproses dan melakukan segmentasi *masking* dan menghitung area kerusakan pada daun dengan durasi singkat dan efisien. Waktu pemrosesan rata rata 2 detik per *frame*. Karena tanaman tergolong target yang tidak bergerak (*statis*), waktu 2 detik ini dianggap memadai dan masuk kategori mendekati waktu-nyata (*near real-time*). Penggunaan komputasi awan (*cloud computing*) ini juga jauh lebih efisien. Beban komputasi yang berat tidak dibebankan pada mikrokontroler, sehingga alat tidak mengalami masalah kehabisan memori (*out of memory*).

3.2.3. Visualisasi Antarmuka Pengguna (*Web Dashboard*)

Output keseluruhan dari seluruh tahapan akuisisi dan segmentasi disajikan pada antarmuka *website* (Gambar 11). *Dashboard* ini secara khusus dirancang untuk menampilkan dua komparasi gambar yang sejajar, yaitu citra asli (RGB) tangkapan CCTV dan citra hasil segmentasi dari model U-Net. Dengan menyisipkan legenda pada panel segmentasi, area daun yang terindikasi rusak akibat hama ditandai dengan warna putih, daun ditandai dengan warna hijau, dan latar belakang di tandai warna hitam. Selain itu tampilan *website* juga dilengkapi dengan rekapan hasil deteksi setiap harinya. Dalam rekapan tersebut ditampilkan 4 gambar yang memiliki identifikasi area daun rusak yang memiliki persentase tertinggi. Nilai persentase ini bersumber dari perhitungan matematis di sisi backend pada Virtual Private Server (VPS). Secara teknis, sistem menghitung total area piksel yang dikenali oleh model sebagai area daun rusak oleh model U-Net, lalu membandingkan dengan jumlah total piksel dalam satu *frame* potongan gambar (resolusi 512x512 piksel). Hasil perbandingan tersebut kemudian dikalikan 100 untuk mendapatkan persentase final. Data persentase yang tersimpan ini kemudian diakses oleh *website* untuk ditampilkan secara *real-time*. Dengan adanya 2 tayangan komparatif beserta metrik kerusakan ini secara langsung memudahkan petani dalam memantau kondisi tanaman pakcoy dari jarak jauh, sehingga tindakan penanganan dapat diambil lebih dini dan tepat sasaran.



Gambar 11. Tampilan Dashboard Pemantauan Kerusakan Tanaman Pakcoy.

3.3 Pembahasan

Kinerja hasil model U-Net pada Fold-2 memberikan performa terbaik dengan akurasi global sebesar 96,8% dan *mean intersection over union* (mIoU) mencapai 0,683. Pendekatan segmentasi ini terbukti lebih efektif jika dikomparasi terhadap metode pendeteksian objek standar (*object detection*). Hal ini dikarenakan U-Net mampu memetakan pola kerusakan dalam skala piksel sesuai dengan bentuk alaminya, sehingga menutupi kekurangan metode kotak pembatas (*bounding box*) yang sering mengabaikan detail atau kurang presisi pada objek berukuran kecil dan asimetris. Walaupun sistem berhasil mengenali 3.755 piksel area daun rusak dengan tepat, masih ditemukan margin kesalahan kecil (*false negative*) di area tepi lubang daun. Kendala ini disebabkan oleh adanya gradasi pigmen yang tidak tegas (*blur*) antara jaringan yang mati dan sehat. Kendati demikian, tampilan visual hasil prediksi pada *dashboard* dianggap sudah memadai untuk difungsikan sebagai sistem peringatan dini.

Keberhasilan ini turut didukung oleh integrasi sistem IoT yang berfungsi dengan baik. Sistem lengan kamera yang di kontrol oleh *stepper motor* dan Arduino Nano berbasis algoritma *finite state machine* (FSM berhasil memutar dengan sudut pandang hingga 360 derajat secara presisi. Mekanisme ini menyediakan radius pemantauan yang jauh lebih luas ketimbang kamera statis. Protokol RTSP pada CCTV Bardi juga berhasil mengirim data visual ke *server* VPS dengan latensi rendah guna diproses secara *real-time*. Lebih dari itu, ketersediaan *dashboard web* yang menampilkan gambar berdampingan sangat membantu petani dalam memantau area hidroponik dari jarak jauh.

4. Kesimpulan

Penelitian ini berhasil mengembangkan sistem pemantauan cerdas yang mengintegrasikan arsitektur *deep learning* U-Net dengan perangkat keras berbasis IoT guna mendeteksi kerusakan daun pakcoy (*Brassica rapa* L.). Berdasarkan pada hasil implementasi, implementasi kamera bergerak yang dikontrol melalui algoritma *finite state machine* (FSM) dinilai mampu dalam menjangkau area tanam secara 360 derajat, sehingga mampu menuntaskan masalah sudut pandang pada kamera statis. Dari sisi performa kecerdasan buatan, model U-Net (Fold-2) mampu memisahkan piksel area kerusakan daun dengan perolehan akurasi global 96,8% dan *mean intersection over union* (mIoU) sebesar 0,683. Temuan ini menegaskan bahwa pendekatan segmentasi tingkat piksel memberikan presisi lebih baik dalam memetakan kerusakan mikro bila dibandingkan terhadap metode deteksi konvensional berbasis kotak pembatas (*bounding box*). Sebagai implementasi nyata, penelitian ini menghadirkan tampilan *dashboard* pemantauan *real-time* yang menyajikan perbandingan gambar asli dan masker segmentasi. Sistem cerdas ini membantu meringankan tugas petani dalam melakukan deteksi dini serangan hama tanpa wajib turun untuk inspeksi fisik ke lokasi. Walaupun begitu, studi ini masih menemukan kelemahan saat mendeteksi tepi lubang kerusakan yang memiliki gradasi warna halus (*blur*), di mana model kerap bias dalam memisahkan antara jaringan daun mati dan sehat. Sebagai usulan untuk riset berikutnya, di usulkan untuk menyisipkan teknik prapemrosesan penajaman citra (*image sharpening*) atau menggunakan fungsi kerugian *boundary loss* supaya akurasi lebih baik pada tepi objek. Selain itu, pengembangan fitur notifikasi otomatis melalui pesan instan direkomendasikan untuk mempercepat penanganan hama.

Referensi

- [1] A. M. Artemyeva dan A. B. Kurina, "Eco-Geographical and Botanical Patterns of Resistance to Lepidoptera Insects in Brassica rapa L.," *Plants*, vol. 13, no. 5, Mar 2024, doi: 10.3390/plants13050673.
- [2] R. I. Ramadhan, H. Fitriyah, dan E. R. Widasari, "Sistem Deteksi Daun Busuk pada Pakcoy Hidroponik menggunakan Metode Thresholding pada Warna Hue dan Saturasi berbasis Raspberry Pi," 2023. [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>
- [3] O. Shalash *dkk.*, "Enhancing Hydroponic Farming with Machine Learning: Growth Prediction and Anomaly Detection," 2025. doi: 10.2139/ssrn.5079228.
- [4] I. M. Dendi Maysanjaya, "Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network (Classification of Pneumonia Based on Lung X-rays Images using Convolutional Neural Network)," 2020.
- [5] M. W. A. Kesiman, I. G. M. Darmawiguna, I. G. R. M. Putra, dan N. L. P. Kurniawati, "Benchmarking a New Dataset of Traditional Balinese Carving Ornaments for Image Classification Task," European Alliance for Innovation n.o., Mar 2022. doi: 10.4108/eai.27-11-2021.2315534.
- [6] I. D. G. A. W. Natih, M. W. A. Kesiman, dan I. M. G. Sunarya, "Analisis Perbandingan Arsitektur dan Optimizer YOLOv11 untuk Estimasi Buah Kelapa," *RIGGS: Journal of Artificial Intelligence and Digital Business*, vol. 4, no. 4, hlm. 12–19, Nov 2025, doi: 10.31004/riggs.v4i4.3329.
- [7] A. Li, D. Li, dan A. Wang, "A Two-Stage YOLOv5s–U-Net Framework for Defect Localization and Segmentation in Overhead Transmission Lines," *Sensors*, vol. 25, no. 9, Mei 2025, doi: 10.3390/s25092903.
- [8] I. Made, A. Darma Putra, M. Dendi Maysanjaya, M. Windu, dan A. Kesiman, "PENDEKATAN BERBASIS U-NET UNTUK SEGMENTASI HARD EXUDATE DALAM CITRA FUNDUS RETINA," *INSERT: Information System and Emerging Technology Journal*, vol. 4, no. 1, 2023.
- [9] I. M. Dendi Maysanjaya, K. Suwis, S. Atmaja, I. Made, dan G. Sunarya, "SEGMENTASI SOFT EXUDATE PADA CITRA FUNDUS RETINA PASIEN DIABETIC RETINOPATHY BERBASIS U-NET," *INSERT: Information System and Emerging Technology Journal*, vol. 4, no. 2.
- [10] I. B. M. Y. Wirawan, I. M. G. Sunarya, dan I. M. D. Maysanjaya, "Semantic Segmentation of Rice Field Bund on Unmanned Aerial Vehicle Image using UNet," dalam *ICITEE 2022 - Proceedings of the 14th International Conference on Information Technology and Electrical Engineering*, Institute of Electrical and Electronics Engineers Inc., 2022, hlm. 211–216. doi: 10.1109/ICITEE56407.2022.9954091.
- [11] A. López-Quilez, "AI, IoT and Remote Sensing in Precision Agriculture," 1 Maret 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/app15062890.
- [12] P. Merta, I. Made, G. Sunarya, dan D. S. Wahyuni, "Pengembangan Robot Berbasis IOT Sebagai Media Pembelajaran Algoritma Pemrograman Berbasis Blok Pada Mata Pelajaran Informatika Tingkat SMP Kelas VIII," *Kumpulan Artikel Mahasiswa Pendidikan Teknik Informatika (KARMAPATI)*, vol. 14, no. 3, 2025.
- [13] M. Waruwu, "Metode Penelitian dan Pengembangan (R&D): Konsep, Jenis, Tahapan dan Kelebihan," *Jurnal Ilmiah Profesi Pendidikan*, vol. 9, no. 2, hlm. 1220–1230, Mei 2024, doi: 10.29303/jipp.v9i2.2141.
- [14] O. Ronneberger, P. Fischer, dan T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," Mei 2015, [Daring]. Tersedia pada: <http://arxiv.org/abs/1505.04597>

DOI: <https://doi.org/10.31004/riggs.v5i1.6957>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

- [15] T. Rahman dan L. B. Mahanta, "Evaluating the Deep Learning Models Performance for Segmentation of Oral Epithelial Dysplasia: A Histological Data-Driven Approach," *Prabha Materials Science Letters*, vol. 3, no. 1, hlm. 94–104, Sep 2024, doi: 10.33889/PMSL.2024.3.1.007.
- [16] S. Deep Deb, R. Kashyap, A. Abhishek, dan R. Kumar Jha, "Severity estimation of Coffee leaf disease using U-Net and pixel counting mechanism," 2024, doi: 10.1145/3647750.
- [17] I. Made, A. Darma Putra, M. Dendi Maysanjaya, M. Windu, dan A. Kesiman, "PENDEKATAN BERBASIS U-NET UNTUK SEGMENTASI HARD EXUDATE DALAM CITRA FUNDUS RETINA," *INSERT: Information System and Emerging Technology Journal*, vol. 4, no. 1, 2023.
- [18] Moch. N. Annafii, O. V. Putra, T. Harmini, dan N. Trisnaningrum, "Segmentasi Semantik pada Citra Hama Leafblast Menggunakan Unet dan Optimasi Hyperband," *Prosiding Sains Nasional dan Teknologi*, vol. 12, no. 1, hlm. 453–459, Nov 2022, doi: 10.36499/psnst.v12i1.7230.