

Evaluasi Algoritma *Deep Learning* dan Segmentasi Klasik untuk Estimasi Luas serta Nilai Konstanta Daun Pepaya pada Sistem *Smart Garden*

Muhammad Ali Pratama Putra^{1*}, Muhammad Fachrie²

^{1,2}Universitas Teknologi Yogyakarta, Indonesia

*email: muhammad.5220411416@student.uty.ac.id

Info Artikel	ABSTRAK
Dikirim: 11 Oktober 2025 Diterima: 10 November 2025 Diterbitkan: 30 November 2025	
Kata kunci: Daun Pepaya; <i>Deep Learning</i> ; Konstanta Daun; Segmentasi Citra; <i>Smart Garden</i> .	Otomatisasi pada <i>smart garden</i> mulai membutuhkan pemantauan pertumbuhan tanaman yang akurat dan efisien, dengan pengukuran luas daun sebagai salah satu parameter yang penting. Sebuah sistem segmentasi citra dikembangkan untuk menentukan luas dan mengidentifikasi konstanta daun menjari, khususnya tanaman pepaya (<i>Carica papaya L.</i>). Kinerja berbagai algoritma dianalisis secara komprehensif, meliputi segmentasi klasik, <i>machine learning</i> dengan <i>Random Forest Classifier</i> , dan <i>deep learning</i> dengan arsitektur U-Net serta YOLOv11-seg. Pengujian menyeluruh dilakukan dengan mengevaluasi skor IoU, akurasi, <i>recall</i> , dan presisi untuk kinerja segmentasi; nilai RMSE dan MSE untuk akurasi prediksi nilai konstanta; serta waktu pelatihan dan inferensi untuk efisiensi komputasi setiap model. Hasil menunjukkan bahwa model YOLOv11-seg memberikan kinerja segmentasi paling stabil secara keseluruhan, dengan capaian IoU yang tinggi dan konsisten pada objek daun (0.904) dan koin (0.883). Meskipun demikian, untuk tugas identifikasi nilai konstanta, <i>Random Forest</i> memberikan akurasi prediksi terbaik yang ditunjukkan dengan nilai RMSE terendah 0.016. Hasil ini mengonfirmasi potensi signifikan dari metode <i>machine learning</i> dan <i>deep learning</i> untuk diterapkan dalam sistem pertanian digital, guna mendukung otomatisasi pemantauan pertumbuhan tanaman secara presisi.

1. PENDAHULUAN

Teknologi modern telah memberikan peran penting dalam meningkatkan efisiensi dan ketepatan dalam sektor pertanian, memungkinkan petani untuk memantau perkembangan tanaman secara akurat [1]. Salah satu terobosan signifikan adalah penggunaan aplikasi berbasis citra untuk memprediksi pertumbuhan tanaman, yang memfasilitasi pengambilan keputusan secara cepat dan tepat [2]. Dalam konteks ini, luasan daun merupakan salah satu indikator vital untuk mengukur kesehatan tanaman karena pengaruh langsungnya terhadap proses fotosintesis [3], [4]. Ukuran daun yang optimal dapat menjadi penanda bahwa tanaman berkembang dengan baik [2], [3]. Beberapa penelitian sebelumnya telah mengeksplorasi penggunaan pemrosesan citra untuk estimasi luas daun. Penelitian [2] menggunakan Mask R-CNN yang dimodifikasi untuk mengukur luas daun pak Choi. Sejalan dengan ini, tren terkini menunjukkan eksplorasi mendalam pada arsitektur *deep learning* yang juga digunakan dalam penelitian ini. Sebagai contoh, sebuah studi mengembangkan LEAF-Net, sebuah kerangka kerja berbasis YOLOv11 untuk ekstraksi dan analisis daun pada fenotipe multi-tanaman [5], sementara studi lain secara spesifik mengevaluasi efektivitas berbagai *backbone* pada model U-Net untuk segmentasi semantik daun tomat [6]. Penelitian [4], [7] melakukan segmentasi citra untuk mendapatkan luasan


dan nilai konstanta daun berbasis thresholding. Namun, pendekatan-pendekatan ini masih memiliki keterbatasan. Pendekatan deep learning murni [2], [5], [6] seringkali membutuhkan sumber daya komputasi yang besar, sementara metode segmentasi klasik berbasis thresholding [4], [7] sangat rentan terhadap kegagalan dalam kondisi pencahayaan yang tidak seragam dan kesulitan mengisolasi objek secara akurat dari latar belakang yang kompleks.

Bentuk daun menjari (*palmate*) seperti pada tanaman pepaya (*Carica papaya L.*) menghadirkan tantangan komputasi yang unik dibandingkan dengan bentuk daun sederhana. Bentuk daun menjari memiliki struktur yang kompleks dengan lekukan-lekukan dalam dan kontur yang tidak beraturan. Kesalahan dalam mendeteksi batas daun akan mengakibatkan kalkulasi luasan yang tidak valid, sehingga menghambat analisis pertumbuhan yang presisi. Oleh karena itu, penelitian ini secara spesifik berfokus untuk mengevaluasi dan membandingkan berbagai pendekatan, dari metode klasik hingga *deep learning*, guna menemukan solusi yang paling efektif untuk masalah ini. Untuk mengevaluasi metode segmentasi daun menjari, penelitian ini mengadopsi empat algoritma yang mewakili metodologi dalam *computer vision*. Segmentasi klasik berbasis *thresholding* warna dipilih sebagai algoritma dasar untuk merepresentasikan pendekatan tradisional yang efisien secara komputasi. *Random Forest Classifier* diimplementasikan sebagai perwakilan dari metode *machine learning* klasik yang mampu menangani hubungan non-linear antar fitur piksel tanpa memerlukan kompleksitas arsitektur *deep learning*. Arsitektur U-Net dipilih karena kemampuannya yang terbukti andal dalam tugas segmentasi semantik presisi tinggi, terutama berkat mekanisme *skip connection*-nya. Model YOLOv11-seg disertakan sebagai representasi arsitektur *state-of-the-art* dalam segmentasi instan, yang menawarkan keseimbangan antara kecepatan inferensi dan akurasi tinggi.

Kebaruan (*novelty*) utama dari penelitian ini tidak hanya terletak pada perbandingan performa empat metodologi yang berbeda dari klasik hingga *state-of-the-art* tetapi juga pada fokus spesifik terhadap bentuk daun menjari (*palmate*) yang secara komputasi lebih menantang. Penelitian ini secara komprehensif mengevaluasi *trade-off* antara akurasi segmentasi (IoU), akurasi estimasi parameter agronomi (RMSE konstanta daun), dan efisiensi komputasi (waktu inferensi). Hasil evaluasi ini memberikan panduan praktis bagi pengembangan sistem *smart garden* dalam memilih model yang paling seimbang antara presisi dan kelayakan implementasi.

2. METODE PENELITIAN

Metodologi penelitian ini dirancang secara mengevaluasi dan membandingkan efektivitas berbagai algoritma dalam melakukan segmentasi citra daun pepaya. Alur kerja penelitian, yang divisualisasikan pada Gambar 1, dimulai dari tahap persiapan sampel dan akuisisi citra daun dalam kondisi terkontrol.



Gambar 1. Diagram alir penelitian

Penelitian ini melibatkan pengolahan citra mentah yang kemudian digunakan untuk melatih beberapa model segmentasi mencakup segmentasi klasik, *Random Forest*, U-Net, dan YOLOv11-seg untuk menghasilkan prediksi luasan daun dan koin secara otomatis. Hasil prediksi dari setiap model kemudian dibandingkan dengan ground truth untuk menghasilkan metrik evaluasi kuantitatif, seperti *Intersection over Union* (IoU), akurasi, dan efisiensi waktu [8]. Tahap akhir dari metodologi ini adalah menggunakan hasil luasan dari model dengan performa terbaik untuk mengidentifikasi nilai konstanta daun pepaya.

2.1 Model Konseptual

Pendekatan konseptual untuk menghitung luasan daun dalam penelitian ini didasarkan pada dua model utama. Model pertama adalah metode kalibrasi skala menggunakan objek referensi, yang dijelaskan dalam persamaan (1). Dalam model ini, luasan daun aktual (A_L) dihitung dengan memanfaatkan rasio antara luasan daun dalam piksel (A_{PL}) dan luasan koin dalam piksel (A_{PC}), yang kemudian dikalikan dengan luasan fisik koin (A_C) yang telah diketahui sebelumnya. Rasio $\frac{A_C}{A_{PC}}$ berfungsi sebagai faktor konversi dari piksel ke satuan cm^2 , memastikan pengukuran area yang akurat terlepas dari jarak pengambilan gambar [9]. Koin yang digunakan menggunakan koin 500 Rupiah seri 2003 dengan diameter 27mm.

$$A_L = \frac{A_{PL} \times A_C}{A_{PC}} \quad (1)$$


$$A_L = H \times W \times c \quad (2)$$

Persamaan (2) digunakan untuk mengidentifikasi nilai konstanta daun (c). Persamaan ini merupakan metode estimasi yang umum digunakan di bidang agronomi, di mana H adalah panjang dan W adalah lebar maksimum daun [7].

2.2 Metode Pengambilan Data

Metode pengambilan data primer dalam penelitian ini adalah melalui teknik dokumentasi yang melibatkan pengumpulan objek daun pepaya dan koin dalam bentuk foto, yang dilakukan dalam satu sesi pada tanggal 2


April 2025. Penulis menggunakan metode observasi *purposive sampling* untuk mendapatkan sampel daun tanaman pepaya varietas California (*Carica papaya L.*) yang memiliki karakteristik bentuk menjari, memastikan daun berada pada fase pertumbuhan 3-6 bulan dan dalam kondisi sehat tanpa kerusakan signifikan. Citra masukan diambil menggunakan kamera gawai (Samsung Galaxy A14 5G) dan proses penangkapan citra dilakukan di dalam studio box rakitan berukuran 45x32x32cm untuk menjamin kualitas gambar yang baik dan pencahayaan yang optimal seperti pada Gambar 2.



Gambar 2. Visualisasi pengambilan data


2.3 Anotasi dan Augmentasi Citra

Pada tahap persiapan dataset, dilakukan proses anotasi citra secara sistematis untuk menghasilkan data ground truth berkualitas tinggi. Proses ini diawali dengan delineasi manual batas objek menggunakan Adobe Photoshop untuk menciptakan citra biner (*mask*) [10]. Selanjutnya, *mask* tersebut diproses secara terprogram menggunakan *library* OpenCV untuk mengekstraksi representasi poligonal dan *bounding box*. Seluruh informasi anotasi ini kemudian distrukturisasi ke dalam format JSON standar COCO, dengan mendefinisikan tiga label kelas yaitu 'daun', 'koin', dan 'lubang' [11]. Untuk memastikan manajemen data yang efisien dan aksesibilitas, keseluruhan dataset yang telah dianotasi diunggah dan dikelola pada *platform* Roboflow [12]. Alur proses dapat dilihat pada gambar 3.



Gambar 3. Proses anotasi citra

Untuk meningkatkan performa model dan mencegah *overfitting*, dataset diperkaya melalui teknik augmentasi citra [13]. Strategi ini melibatkan penerapan rangkaian transformasi geometris dan fotometri secara acak, yang meliputi rotasi, serta penyesuaian saturasi, kecerahan, dan kontras. Langkah ini memastikan bahwa setiap transformasi yang diterapkan pada citra asli juga diaplikasikan secara identik pada anotasi *mask* yang bersesuaian. Melalui pendekatan ini, dataset berhasil diperluas secara signifikan hingga mencapai 200 gambar, menyediakan variasi data yang lebih kaya untuk melatih model agar mampu bergeneralisasi lebih baik terhadap kondisi data yang belum pernah dilihat [14].




Gambar 4. Augmentasi citra daun dan *mask*

2.4 Metode Segmentasi

Untuk mencapai tujuan utama penelitian, dirancang sebuah eksperimen guna menganalisis dan membandingkan secara komprehensif empat pendekatan segmentasi citra yang berbeda. Metode-metode yang diuji dipilih untuk merepresentasikan spektrum teknologi yang luas, mulai dari teknik segmentasi klasik yang fundamental hingga arsitektur *machine learning* dan *deep learning* modern. Setiap pendekatan diimplementasikan secara sistematis untuk dievaluasi kinerjanya dalam tugas spesifik identifikasi luasan daun pepaya.

2.4.1 Metode Segmentasi Klasik Berbasis Thresholding


Pendekatan pertama memanfaatkan teknik segmentasi klasik yang bekerja langsung pada properti intrinsik gambar tanpa melalui tahap pelatihan. Untuk mengisolasi area daun, citra dikonversi ke ruang warna HSV (*Hue, Saturation, Value*) dan disegmentasi menggunakan *Range Thresholding* pada rentang (30, 50, 50) hingga (95, 255, 255) yang tahan terhadap variasi pencahayaan. Sementara itu, objek koin diidentifikasi pada citra *grayscale* dengan *thresholding* berdasarkan nilai kecerahan antara 180 dan 240. Hasil segmentasi biner kemudian disempurnakan melalui deteksi kontur dan operasi morfologi untuk membersihkan derau [4].



Gambar 5. Diagram alir pada metode segmentasi klasik

2.4.2 Metode Segmentasi dengan Machine Learning (Random Forest Classifier)


Metode kedua menggunakan pendekatan *machine learning* dengan algoritma *Random Forest Classifier* untuk melakukan klasifikasi pada level piksel [15]. Setiap piksel direpresentasikan oleh fitur berupa nilai kanalnya dalam ruang warna HSV. Sebuah model *Random Forest* yang terdiri dari 100 *decision tree* ($n\_estimators=100$), *max_depth* sebesar 20, *random_state* 42, dan n_jobs senilai -1. Model ini dilatih untuk memprediksi kelas setiap piksel berdasarkan fitur warnanya. Hasil prediksi dari seluruh piksel kemudian direkonstruksi menjadi sebuah mask segmentasi final yang memisahkan objek daun, koin, dan lubang dari latar belakang.



Gambar 6. Diagram alir pada metode *machine learning*

2.4.3 Metode Segmentasi Semantik dengan U-Net

Pendekatan ketiga menerapkan arsitektur *deep learning* U-Net, yang dirancang khusus untuk tugas segmentasi semantik dengan presisi tinggi [16]. Model ini terdiri dari jalur *encoder* untuk ekstraksi fitur hirarkis dan jalur *decoder* untuk rekonstruksi mask spasial. Keunggulan utamanya terletak pada mekanisme *skip connections* yang menghubungkan *feature map* dari *encoder* ke *decoder*, memungkinkan pemulihan detail spasial yang halus untuk menghasilkan delineasi objek yang akurat. Citra masukan yang telah dinormalisasi diumpankan ke model untuk menghasilkan prediksi *mask* probabilitas, yang kemudian difilter menggunakan ambang batas kepercayaan (*Confidence Threshold*). Model ini dilatih selama 80 *epoch* dengan ukuran *batch* 8 dan *learning rate* 1×10^{-3} , menggunakan *optimizer* Adam.




Gambar 7. Diagram alir pada metode segmentasi semantik

2.4.4 Metode Segmentasi Instan dengan YOLOv11-seg

Pendekatan keempat memanfaatkan model YOLOv11-seg untuk tugas segmentasi instan (*instance segmentation*), yang secara simultan mendeteksi lokasi setiap objek dan menghasilkan mask segmentasi unik untuk setiap instans. Sebagai arsitektur *one-stage detector*, model ini sangat efisien karena mampu melakukan deteksi dan segmentasi dalam satu kali proses inferensi. Dalam penelitian ini, digunakan bobot pra-terlatih (*pre-trained weights*) dari varian YOLOv11s-seg yang kemudian disesuaikan (*fine-tuned*) pada dataset spesifik

penelitian. Hasil prediksi berupa *bounding box* dan *mask* kemudian disaring menggunakan *confidence threshold* untuk memvalidasi objek yang relevan [17]. Pelatihan *fine-tuning* dilakukan selama 10 *epoch* dengan ukuran *batch* 16, *learning rate* awal 0.01, dan *optimizer* Adam.



Gambar 8. Diagram alir pada metode segmentasi instan

2.5 Lingkungan Eksperimen

Seluruh proses pelatihan serta pengujian model dalam penelitian ini dieksekusi menggunakan platform *cloud computing* Google Colaboratory (Colab). Lingkungan eksperimen ini menggunakan *runtime* T4 GPU, yang mencakup perangkat keras berupa 1x NVIDIA T4 GPU (16 GB VRAM), CPU Intel Xeon (arsitektur x86_64, 2-core), dan RAM 12.7 GB. Dari sisi perangkat lunak, sistem ini berjalan di atas sistem operasi Linux (Ubuntu 22.04 LTS) dan menggunakan Python 3.10 sebagai bahasa pemrograman utama. Pemodelan *deep learning* dikembangkan menggunakan *framework* TensorFlow v2.15, sementara *library* pendukung utama meliputi Scikit-learn untuk model Random Forest dan OpenCV untuk pemrosesan citra.

2.6 Metrik Evaluasi

Untuk mengukur dan membandingkan kinerja dari setiap model segmentasi secara kuantitatif dan objektif, serangkaian metrik evaluasi standar dalam bidang *Computer Vision* diterapkan. Metrik-metrik ini dipilih untuk menilai berbagai aspek performa model, mulai dari akurasi spasial pada tingkat piksel, efektivitas klasifikasi, hingga efisiensi komputasi.

2.5.1 Intersection over Union (IoU)

Intersection over Union (IoU), atau *Jaccard Index*, adalah metrik utama yang digunakan untuk mengevaluasi akurasi spasial pada tugas segmentasi. Metrik ini mengukur tingkat tumpang tindih antara *mask* segmentasi yang diprediksi oleh model (A) dengan *mask ground truth* (B). Nilai IoU berkisar dari 0 (tidak ada tumpang tindih) hingga 1 (tumpang tindih sempurna), di mana skor yang lebih tinggi menunjukkan bahwa model mampu melokalisasi dan mendelineasi batas objek dengan lebih presisi [8].

$$IoU(A, B) = \frac{Area(A \cap B)}{Area(A \cup B)} \quad (3)$$

2.5.2 Metrik Berbasis Confusion Matrix

Untuk menganalisis kinerja klasifikasi pada level piksel, digunakan *Confusion Matrix* yang memvisualisasikan hasil prediksi dalam empat kategori utama: *True Positives* (TP), *False Positives* (FP), *False Negatives* (FN), dan *True Negatives* (TN). Skor akurasi mengukur proporsi total piksel yang diklasifikasikan dengan benar. Skor presisi menilai proporsi prediksi positif yang benar-benar akurat. Skor recall mengukur kemampuan model untuk menemukan semua piksel objek yang relevan [18].

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$Presisi = \frac{TP}{TP + FP} \quad (5)$$

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

2.5.3 Root Mean Squared Error (RMSE)

Untuk mengevaluasi kinerja model dalam memprediksi nilai konstanta daun, yang merupakan tugas regresi, digunakan metrik *Root Mean Squared Error* (RMSE). RMSE mengukur rata-rata magnitudo kesalahan antara nilai yang diprediksi ($\hat{y}_i$) dengan nilai aktual (y_i) dalam satuan yang sama dengan variabel target. Metrik ini memberikan bobot yang lebih besar pada kesalahan yang besar karena adanya proses pengkuadratan, sehingga sensitif terhadap *outlier* [7].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

2.5.4 Efisiensi Waktu

Selain akurasi, efisiensi komputasi juga dievaluasi untuk menilai kelayakan praktis setiap model. Evaluasi ini mencakup dua aspek. Waktu Pelatihan yaitu durasi total yang dibutuhkan model untuk belajar dari dataset hingga konvergen. Waktu Inferensi yaitu kecepatan model dalam menghasilkan prediksi untuk satu gambar baru. Kedua metrik ini sangat penting untuk memahami *trade-off* antara akurasi model dan efisiensi operasionalnya, terutama untuk aplikasi yang sensitif terhadap latensi [19].

3. HASIL DAN PEMBAHASAN

Analisis dilakukan secara kualitatif melalui perbandingan visual dan secara kuantitatif melalui metrik performa yang telah ditetapkan. Pembahasan difokuskan pada dua aspek utama yaitu kemampuan setiap metode dalam melakukan segmentasi daun dan akurasinya dalam mengidentifikasi nilai konstanta daun.

3.1 Analisis Performa Segmentasi Daun

Untuk analisis kuantitatif yang lebih mendalam, kinerja segmentasi dari keempat model yang diuji disajikan secara komparatif pada Tabel 1. Tabel ini merinci metrik-metrik evaluasi utama, yaitu skor IoU, Presisi, Recall, dan Akurasi. Performa setiap model dianalisis secara terpisah untuk dua kelas objek krusial: 'Daun' sebagai objek utama dan 'Koin' sebagai objek referensi skala. Hasil disajikan dalam format rata-rata $\pm$ standar deviasi yang dihitung dari keseluruhan data uji. Rata-rata menunjukkan performa tipikal model, sementara standar deviasi mengindikasikan tingkat konsistensi atau variabilitas kinerja model pada berbagai sampel pengujian.


Tabel 1. Perbandingan hasil performa antar model dalam segmentasi

Metode	Objek	IoU*	Presisi*	Recall*	Akurasi*
Segmentasi Klasik	Daun	0.594 $\pm$ 0.404	0.641 $\pm$ 0.421	0.641 $\pm$ 0.435	0.549 $\pm$ 0.368
	Koin	0.004 $\pm$ 0.001	0.004 $\pm$ 0.007	0.300 $\pm$ 0.458	
Random Forest	Daun	0.953 $\pm$ 0.008	0.954 $\pm$ 0.008	0.999 $\pm$ 0.001	0.981 $\pm$ 0.006
	Koin	0.511 $\pm$ 0.422	0.596 $\pm$ 0.486	0.514 $\pm$ 0.425	
U-Net	Daun	0.928 $\pm$ 0.017	0.938 $\pm$ 0.017	0.989 $\pm$ 0.011	0.966 $\pm$ 0.006
	Koin	0	0	0	
YOLOv11-seg	Daun	0.904 $\pm$ 0.017	0.910 $\pm$ 0.014	0.993 $\pm$ 0.007	0.966 $\pm$ 0.005
	Koin	0.883 $\pm$ 0.019	0.884 $\pm$ 0.020	0.998 $\pm$ 0.003	

*Nilai sudah dihitung rata-rata pada data uji

Analisis pada Tabel 1 menyoroti perbedaan signifikan dalam performa dan konsistensi antar model. Metode segmentasi klasik menunjukkan kinerja yang tidak stabil, dibuktikan dengan standar deviasi yang sangat tinggi

(± 0.404 pada IoU daun). Sementara itu, baik *Random Forest* maupun U-Net menunjukkan performa yang timpang. *Random Forest* sangat presisi pada daun (IoU 0.953 ± 0.008) namun sangat tidak konsisten pada koin (IoU 0.511 ± 0.422), sedangkan U-Net secara konsisten gagal total mendeteksi koin (IoU 0). Hal ini menjadikan YOLOv11-seg sebagai metode yang paling unggul secara keseluruhan. Meskipun IoU-nya pada daun (0.904 ± 0.017) sedikit di bawah *Random Forest*, keunggulannya terletak pada performa yang tinggi dan sangat konsisten pada kedua objek, terutama pada koin (IoU 0.883 ± 0.019). Kemampuan yang seimbang menjadi pilihan paling baik untuk implementasi praktis.



Gambar 9. Hasil segmentasi antar model

Analisis kualitatif pada gambar 9 secara visual mengonfirmasi temuan kuantitatif, menyoroti keunggulan dan kelemahan setiap metode. Metode segmentasi klasik menghasilkan prediksi yang dipenuhi derau dan gagal mendeteksi koin. Sementara itu, *Random Forest* dan U-Net mampu menghasilkan *mask* daun yang sangat bersih, namun keduanya menunjukkan kelemahan pada deteksi objek referensi. *Random Forest* menghasilkan bentuk koin yang tidak presisi, dan U-Net gagal total mendeteksinya. Hal ini mengukuhkan YOLOv11-seg sebagai pendekatan yang paling baik, karena menjadi satu-satunya metode yang berhasil mendeteksi dan mensegmentasi kedua objek krusial (daun dan koin) secara bersamaan, meskipun dengan sedikit derau pada hasil akhirnya.

Tabel 2. Perbandingan performa waktu antar model

Metode	Waktu latih*	Waktu prediksi*
Segmentasi Klasik	-	0,07
Random Forest	41	0,68
U-Net	6.671	1,86
YOLOv11-seg	326	1,32

*Nilai dengan satuan sekon

Analisis pada Tabel 2 menyoroti efisiensi komputasi yang bervariasi antar model. Metode segmentasi klasik menjadi yang tercepat dalam inferensi (0,07 detik) karena tidak memerlukan waktu pelatihan. Di antara model berbasis pembelajaran, *Random Forest* adalah yang paling efisien, dengan waktu pelatihan hanya 41 detik dan inferensi 0,68 detik. Sebaliknya, U-Net terbukti paling tidak efisien dengan waktu pelatihan yang sangat lama yaitu 6.671 detik dan inferensi terlambat (1,86 detik). YOLOv11-seg menawarkan performa terbaik di antara model *deep learning*, dengan waktu pelatihan yang jauh lebih wajar (326 detik) dan waktu inferensi yang kompetitif (1,32 detik). Hasil ini menunjukkan bahwa YOLOv11-seg memberikan keseimbangan yang paling praktis dengan biaya komputasi yang dapat diterima.


3.2 Hasil Identifikasi Konstanta Daun

Setelah mengevaluasi performa segmentasi, analisis dilanjutkan untuk mengukur akurasi setiap model dalam tugas akhir, yaitu identifikasi nilai konstanta daun. Tabel 3 menyajikan perbandingan kinerja regresi ini menggunakan metrik *Mean Squared Error* (MSE) dan *Root Mean Squared Error* (RMSE). Kedua metrik ini mengukur rata-rata magnitudo kesalahan antara nilai konstanta yang diprediksi dengan nilai konstanta aktual dari data *ground truth*. Nilai MSE dan RMSE yang lebih rendah mengindikasikan bahwa model memiliki tingkat kesalahan yang lebih kecil dan, dengan demikian, lebih akurat dalam prediksinya.

Tabel 3. Perbandingan performa antar model dalam identifikasi konstanta daun

Metode	MSE	RMSE
Segmentasi Klasik	0.075	0.273
Random Forest	0.0002	0.016
U-Net	0.001	0.030
YOLOv11-seg	0.002	0.052

Tabel 3 secara jelas mengidentifikasi akurasi setiap model dalam tugas akhir, yaitu prediksi nilai konstanta daun. Hasilnya menunjukkan bahwa Random Forest secara signifikan mengungguli metode lainnya, mencapai tingkat kesalahan terendah dengan RMSE hanya 0.016. Model *deep learning*, U-Net dan YOLOv11-seg, juga menunjukkan tingkat akurasi yang tinggi dengan nilai RMSE yang rendah, masing-masing 0.030 dan 0.052. Performa superior dari ketiga model ini dibandingkan dengan Segmentasi Klasik (RMSE 0.273) divisualisasikan dengan jelas pada Gambar 10. Grafik korelasi tersebut menunjukkan bagaimana prediksi dari *Random Forest*, U-Net, dan YOLOv11-seg (titik oranye, hijau, merah) terkumpul sangat rapat di dekat garis prediksi sempurna ($y=x$). Sebaliknya, prediksi Segmentasi Klasik (titik biru) menyimpang jauh, yang mengonfirmasi bahwa kegagalan pada tahap segmentasi awal berdampak langsung pada ketidakakuratan hasil akhir.



Gambar 10. Grafik perbandingan nilai konstanta

Analisis kuantitatif lebih lanjut pada Tabel 3 mengonfirmasi signifikansi hasil penelitian. Model *Random Forest* (RMSE 0.016) secara drastis mengurangi tingkat kesalahan hingga lebih dari 94% dibandingkan dengan metode Segmentasi Klasik (RMSE 0.273). Demikian pula, pada tugas segmentasi di Tabel 1, *Random Forest* (IoU daun 0.953) dan YOLOv11-seg (IoU daun 0.904) menunjukkan peningkatan akurasi segmentasi yang substansial dibandingkan Segmentasi Klasik (IoU Daun 0.594). Perbedaan performa yang sangat besar ini membuktikan bahwa adopsi metode *machine learning* dan *deep learning* memberikan peningkatan kinerja yang signifikan secara praktis. Temuan ini memiliki implikasi praktis yang kuat untuk otomatisasi pemantauan kesehatan tanaman di lapangan. Meskipun *Random Forest* memberikan nilai RMSE terendah untuk estimasi konstanta, YOLOv11-seg terbukti sebagai model yang paling seimbang dan siap pakai berkat kemampuannya yang konsisten dalam mendeteksi kedua objek (daun dan koin) secara bersamaan. Dalam sistem *smart garden*

di dunia nyata, kemampuan untuk secara andal mendeteksi objek referensi (koin) dalam berbagai kondisi pencahayaan sangat krusial untuk kalibrasi skala yang akurat. Oleh karena itu, model YOLOv11-seg dapat diintegrasikan ke dalam sistem pemantauan otomatis untuk melacak laju pertumbuhan daun secara *real-time*, memberikan data penting bagi petani untuk pengambilan keputusan terkait irigasi, pemupukan, atau deteksi stres tanaman.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem berbasis web fungsional dan secara komprehensif membandingkan empat metode segmentasi untuk analisis luasan daun pepaya. Hasil evaluasi menunjukkan bahwa pendekatan berbasis *deep learning* dan *machine learning* jauh lebih unggul daripada metode klasik. Secara spesifik, YOLOv11-seg terbukti menjadi model yang paling stabil dan efektif secara keseluruhan, berkat kemampuannya yang seimbang dan konsisten dalam mendeteksi objek utama (daun) dan objek referensi (koin) secara bersamaan. Penelitian ini menetapkan nilai konstanta daun pepaya rata-rata sebesar 0.543, yang dapat menjadi acuan representatif untuk estimasi luas daun. Keberhasilan validasi model YOLOv11-seg sebagai pendekatan paling seimbang membuka potensi penerapan hasil ini pada sistem deteksi otomatis di lapangan. Sistem ini dapat diimplementasikan pada perangkat *edge computing* atau *drone* untuk melakukan analisis *real-time* di lokasi pertanian, mendukung keputusan agronomi secara presisi.

Untuk pengembangan di masa depan, penelitian ini membuka beberapa jalan bagi peneliti selanjutnya. Prioritas utama adalah pengayaan dataset dengan citra yang lebih beragam, mencakup variasi pencahayaan, latar belakang yang kompleks, serta berbagai kondisi kesehatan daun untuk meningkatkan generalisasi model. Dari sisi metodologi, optimasi lebih lanjut pada arsitektur YOLOv11-seg dapat dilakukan untuk meningkatkan presisi. Selain itu, cakupan penelitian dapat diperluas dengan mengadaptasi sistem untuk menganalisis varietas tanaman lain dengan morfologi daun yang berbeda.

REFERENSI

- [1] L. L. Meena, M. Jena, M. S. Sardar, U. Pradhan, Dan A. K. Prusty, "How Smart Technologies In Agriculture Are Revolutionizing Farming Practices," *International Journal Of Agriculture Extension And Social Development*, Vol. 7, No. 12, Hlm. 30–36, Des 2024, Doi: 10.33545/26180723.2024.V7.I12a.1376.
- [2] F. Huang, Y. Li, Z. Liu, L. Gong, Dan C. Liu, "A Method For Calculating The Leaf Area Of Pak Choi Based On An Improved Mask R-Cnn," *Agriculture*, Vol. 14, No. 1, Hlm. 101, Jan 2024, Doi: 10.3390/Agriculture14010101.
- [3] Y. Sun, B. Wang, Dan Z. Zhang, "Improving Leaf Area Index Estimation With Chlorophyll Insensitive Multispectral Red-Edge Vegetation Indices," *Ieee J Sel Top Appl Earth Obs Remote Sens*, Vol. 16, Hlm. 3568–3582, 2023, Doi: 10.1109/Jstars.2023.3262643.
- [4] R. Andrian, A. Agustiansyah, A. Junaidi, Dan D. I. Lestari, "Aplikasi Pengukuran Luas Daun Tanaman Menggunakan Pengolahan Citra Digital Berbasis Android," *Jurnal Agrotropika*, Vol. 21, No. 2, Hlm. 115, Okt 2022, Doi: 10.23960/Ja.V21i2.6096.
- [5] A. T. Khan Dan S. M. Jensen, "Leaf-Net: A Unified Framework For Leaf Extraction And Analysis In Multi-Crop Phenotyping Using Yolov11," *Agriculture (Switzerland)*, Vol. 15, No. 2, Jan 2025, Doi: 10.3390/Agriculture15020196.
- [6] J. P. Guerra Ibarra, F. J. Cuevas De La Rosa, Dan J. R. Hernandez Vidales, "Evaluation Of The Effectiveness Of The Unet Model With Different Backbones In The Semantic Segmentation Of Tomato Leaves And Fruits," *Horticulturae*, Vol. 11, No. 5, Mei 2025, Doi: 10.3390/Horticulturae11050514.
- [7] F. M. Al Ramadhani, "Identifikasi Nilai Konstanta Daun Tanaman Rambutan Dan Jambu Air Berbasis Pengolahan Citra Digital," *Jurnal Penelitian Inovatif*, Vol. 4, No. 2, Hlm. 655–664, Mei 2024, Doi: 10.54082/Jupin.400.
- [8] B. R. Pratama, F. T. Anggraeny, Dan A. Junaidi, "Segmentasi Optic Cup Dan Optic Disc Menggunakan U-Net Backbone Resnet50," Vol. 11, 2025.

- [9] E. W. Triyani, “Implementasi *Deep Learning* Untuk Deteksi Makanan Dan Estimasi Kalori Menggunakan Yolov11,” Uin Sunan Gunung Djati Bandung, 2025. Doi: 10/10_Daftar pustaka.Pdf.
- [10] - Muhammad Ramadhan Maulana. A, “Pemetaan Dan Identifikasi Kesiapan Petik Tanaman Teh Berdasarkan Citra Drone Menggunakan Mask Region-Based Convolutional Neural Network (Mask R-Cnn) Dan Green Leaf Index (Gli),” Universitas Pendidikan Indonesia, 2023. [Daring]. Tersedia Pada: <https://Repository.Upi.Edu/>
- [11] J. Arifianto, “Aplikasi Web Pendeteksi Jerawat Pada Wajah Menggunakan Model *Deep Learning* Dengan Tensorflow,” Jan 2022, [Daring]. Tersedia Pada: <https://Dspace.Uii.Ac.Id/Handle/123456789/37886>
- [12] N. Sary, H. H. S. Pasaribu, R. J. Situmeang, Dan R. Darmawan, “Implementasi Algoritma Yolov11 Dan Roboflow Untuk Deteksi Tingkat Kematangan Anggur Berbasis Web,” Vol. 9, 2025.
- [13] M. M. Nugraha, M. D. F. Saputra, D. A. Fauzan, Dan E. Y. Puspaningrum, “Augmentasi Data Pengenalan Citra Batik Yogyakarta Menggunakan Pendekatan Random Crop, Rotate, Dan Mixup,” Vol. 5, 2025.
- [14] C. Adi Cahya, “Penerapan Yolov11 Dengan Instance Segmentation Untuk Segmentasi Genangan Air Pada Permukaan Ruas Jalan,” Institut Teknologi Kalimantan, 2025. [Daring]. Tersedia Pada: <https://Repository.Itk.Ac.Id/23937/>
- [15] B. R. Chughtai Dan A. Jalal, “Object Detection And Segmentation For Scene Understanding Via Random Forest,” Dalam *2023 4th International Conference On Advancements In Computational Sciences (Icacs)*, 2023, Hlm. 1–6. Doi: 10.1109/Icacs55311.2023.10089658.
- [16] S. Zhang Dan C. Zhang, “Modified U-Net For Plant Diseased Leaf Image Segmentation,” *Comput Electron Agric*, Vol. 204, Hlm. 107511, Jan 2023, Doi: 10.1016/J.Compag.2022.107511.
- [17] R. Khanam Dan M. Hussain, “Yolov11: An Overview Of The Key Architectural Enhancements,” Oktober 2024, *Arxiv*. Doi: 10.48550/Arxiv.2410.17725.
- [18] A. Fakihi, M. A. Hamzami, M. R. Hadiano, Dan N. I. S. Alifah, “Perbandingan Akurasi Algoritma C4.5 Dan K-Nn Untuk Prediksi Kelulusan Mahasiswa Penerima Beasiswa,” *Jurnal Komputer Antartika*, Vol. 3, No. 1, Hlm. 18–25, Jan 2025, Doi: 10.70052/Jka.V3i1.623.
- [19] G. Verma, Y. Gupta, A. M. Malik, Dan B. Chapman, “Performance Evaluation Of *Deep Learning* Compilers For Edge Inference,” Dalam *2021 Ieee International Parallel And Distributed Processing Symposium Workshops (Ipdpw)*, 2021, Hlm. 858–865. Doi: 10.1109/Ipdpsw52791.2021.00128.