Copyright © The Author(s) 2026
Jurnal Artificial, Vol 4 No 2, Oktober 2026

Deep Learning Berbasis U-Net untuk Segmentasi Citra Daun Kakao dalam Deteksi Dini Penyakit Tanaman

Maylian Flasmawati [1*], A. Taqwa Martadinata [2], Nelly Khairani Daulay [3], Bunga Intan [4]

[1, 2, 3, 4] Universitas Bina Insan, Indonesia

* maylianmay09@gmail.com

Abstrak

Penyakit pada tanaman kakao dapat memengaruhi kondisi dan produktivitas tanaman sehingga diperlukan pendekatan berbasis pengolahan citra untuk mendukung proses deteksi secara lebih efektif. Salah satu tahap penting dalam analisis citra daun adalah segmentasi untuk memisahkan objek daun dari latar belakang sehingga informasi area pada citra dapat dianalisis lebih lanjut. Penelitian ini bertujuan menerapkan metode *deep learning* berbasis U-Net untuk melakukan segmentasi citra daun kakao sebagai tahap awal dalam mendukung deteksi dini penyakit tanaman. Data yang digunakan berupa citra digital daun kakao beserta *ground-truth mask* yang dianotasi secara piksel. Tahapan penelitian meliputi prapemrosesan dengan *resize* citra menjadi 224×224 piksel, normalisasi nilai piksel, pembentukan *binary mask*, pembagian dataset menjadi data *training*, *validation*, dan *testing* dengan proporsi 80:10:10, serta pelatihan model U-Net menggunakan optimizer Adam, *Binary Crossentropy*, 10 *epoch*, dan *batch size* 8. Evaluasi dilakukan menggunakan *Accuracy*, *Intersection over Union* (IoU), dan *Dice Coefficient*. Hasil pengujian menunjukkan nilai *Accuracy* sebesar 98%, IoU sebesar 91%, dan *Dice Coefficient* sebesar 94%. Pada salah satu citra pengujian, area yang terindikasi mengalami penyakit sebesar 20,33% dari keseluruhan area daun. Hasil tersebut menunjukkan bahwa U-Net mampu melakukan segmentasi citra daun kakao dengan baik dan dapat menjadi tahap pendukung dalam pengembangan sistem deteksi dini penyakit tanaman. Penelitian selanjutnya dapat mengintegrasikan hasil segmentasi dengan metode klasifikasi untuk mengidentifikasi jenis penyakit secara otomatis.

Kata Kunci: *Daun Kakao, Deep Learning, Deteksi Dini Penyakit, Segmentasi Citra, U-Net*

Pendahuluan

Kakao (*Theobroma cacao* L.) merupakan komoditas perkebunan tropis yang memiliki nilai ekonomi penting dan menjadi sumber pendapatan bagi jutaan petani kecil di berbagai negara penghasil kakao. Tanaman ini juga menjadi bahan baku utama industri cokelat dan memiliki nilai ekonomi yang luas pada sektor pangan maupun industri turunannya (Wickramasuriya & Dunwell, 2018). Perkembangan produksi kakao menghadapi berbagai kendala, termasuk faktor biologis, lingkungan, teknologi budidaya, serta kondisi sosial-ekonomi yang memengaruhi keberlanjutan produksi (Jagoret et al., 2021). Salah satu kendala biologis yang perlu mendapat perhatian adalah penyakit tanaman karena sejumlah patogen dapat menyebabkan kerusakan pada jaringan tanaman dan menurunkan produktivitas kakao (Marelli et al., 2019). Penyakit kakao juga memiliki sejarah penyebaran yang berkaitan dengan perpindahan bahan tanam dan perkembangan kawasan produksi, sehingga pengelolaan penyakit menjadi salah satu

https://doi.org/10.54065/artificial.4.2.2026.2022

aspek penting dalam menjaga keberlanjutan komoditas tersebut (Díaz-Valderrama et al., 2020).

Daun merupakan salah satu bagian tanaman yang dapat memberikan informasi visual mengenai kondisi kesehatan tanaman. Gejala penyakit pada daun dapat muncul dalam berbagai bentuk, seperti perubahan warna, bercak, perubahan tekstur, nekrosis, dan perubahan struktur jaringan, sehingga citra daun dapat digunakan sebagai sumber informasi untuk proses identifikasi kondisi tanaman (Kaur et al., 2019). Pendekatan berbasis citra berkembang karena pemeriksaan penyakit secara manual membutuhkan pengamatan oleh manusia dan dapat menghadapi kendala berupa waktu pemeriksaan, kebutuhan tenaga ahli, serta subjektivitas dalam menentukan kondisi tanaman (Sinha & Shekhawat, 2020). Penggunaan teknologi pengolahan citra dan pembelajaran mesin kemudian menjadi salah satu pendekatan yang dikembangkan untuk membantu proses identifikasi penyakit tanaman secara lebih sistematis (Ngugi et al., 2021).

Perkembangan *Computer Vision* dan *Deep Learning* memberikan peluang untuk membangun sistem analisis tanaman berbasis citra digital. Sejumlah penelitian menunjukkan bahwa metode berbasis *Deep Learning*, khususnya *Convolutional Neural Network* (CNN), telah banyak diterapkan dalam identifikasi penyakit tanaman karena mampu mempelajari karakteristik visual secara otomatis dari citra (Boulent et al., 2019). Penggunaan *Deep Learning* juga telah diterapkan pada berbagai jenis tanaman dengan hasil yang menunjukkan potensi untuk melakukan identifikasi penyakit berdasarkan citra daun (Ferentinos, 2018). Kajian sistematis terhadap penelitian deteksi penyakit tanaman juga menunjukkan bahwa penggunaan sensor citra dan metode *machine learning* merupakan salah satu arah utama dalam pengembangan teknologi pendeteksian penyakit tanaman (Bischoff et al., 2021; Rayhan, 2026).

Salah satu tahapan penting dalam analisis citra tanaman adalah segmentasi. Segmentasi bertujuan memisahkan objek yang menjadi perhatian dari latar belakang atau membagi citra ke dalam wilayah tertentu berdasarkan karakteristik piksel sehingga informasi spasial objek dapat dianalisis secara lebih terperinci (Sodjinou et al., 2022). Dalam konteks penyakit tanaman, segmentasi dapat digunakan untuk memisahkan daun dari latar belakang maupun mengidentifikasi wilayah yang menunjukkan gejala penyakit pada tingkat piksel (Chen et al., 2021). Pendekatan *semantic segmentation* juga memungkinkan setiap piksel diberikan label tertentu sehingga luas area yang terdampak dapat dihitung dan digunakan sebagai informasi tambahan dalam analisis tingkat keparahan penyakit (Khan et al., 2022).

Penerapan segmentasi pada citra tanaman memiliki tantangan tersendiri karena karakteristik objek dapat berubah akibat perbedaan bentuk, ukuran, warna, tekstur, pencahayaan, dan kondisi latar belakang. Pada citra daun berpenyakit, area gejala juga dapat berukuran kecil, memiliki bentuk tidak beraturan, serta mempunyai batas yang tidak tegas dengan jaringan daun yang sehat (Zhang & Zhang, 2023). Kondisi serupa ditemukan pada segmentasi penyakit daun apel, ketika keberadaan objek yang saling tumpang tindih dan kondisi citra yang kompleks dapat mengganggu proses pemisahan daun maupun area penyakit (Zhu et al., 2023). Penelitian pada penyakit daun anggur juga menunjukkan bahwa segmentasi secara semantik dapat digunakan untuk memperoleh informasi spasial mengenai distribusi area penyakit pada daun dan mendukung proses kuantifikasi gejala penyakit (Liu et al., 2022).

Salah satu arsitektur *Deep Learning* yang banyak digunakan untuk permasalahan segmentasi adalah U-Net. Arsitektur U-Net menggunakan struktur *encoder-decoder* dan hubungan antarlapisan untuk menggabungkan informasi semantik dengan informasi spasial sehingga proses rekonstruksi objek pada resolusi yang lebih tinggi dapat dilakukan secara lebih terperinci. Penerapan U-Net pada segmentasi tanaman menunjukkan bahwa pendekatan tersebut dapat digunakan untuk memisahkan objek tanaman dari latar belakang pada citra pertanian (Sodjinou et al., 2022). U-Net juga telah diterapkan pada segmentasi daun dan penyakit tanaman, baik sebagai arsitektur dasar maupun sebagai dasar pengembangan model yang lebih kompleks (Chowdhury et al., 2021).

Penelitian terdahulu memperlihatkan bahwa U-Net dan berbagai pengembangannya telah digunakan pada segmentasi penyakit tanaman dengan karakteristik objek yang berbeda. Penerapan U-Net pada segmentasi bercak penyakit daun jagung menunjukkan bahwa arsitektur tersebut dapat digunakan untuk memperoleh area penyakit pada tingkat piksel (Liu et al., 2021). Pada daun padi, pengembangan model berbasis U-Net dengan mekanisme *attention* dan ekstraksi fitur multi-skala menunjukkan potensi dalam melakukan segmentasi penyakit sekaligus memperkirakan tingkat keparahan penyakit (Chen et al., 2020). Penerapan MC-UNet pada citra daun tomat juga menunjukkan bahwa kombinasi *multi-scale convolution* dan *cross-layer attention fusion* dapat digunakan untuk menangani karakteristik area penyakit yang berukuran kecil dan memiliki batas yang kurang jelas (Deng et al., 2023). Hasil penelitian tersebut menunjukkan bahwa arsitektur U-Net dapat diterapkan pada berbagai objek tanaman dan karakteristik penyakit, meskipun konfigurasi serta modifikasi model perlu disesuaikan dengan karakteristik data yang digunakan.

Perkembangan penelitian selanjutnya menunjukkan adanya berbagai modifikasi terhadap U-Net untuk meningkatkan kemampuan segmentasi pada kondisi citra tanaman yang kompleks. Modifikasi U-Net dengan *residual block* dan *residual path* dikembangkan untuk meningkatkan kemampuan ekstraksi serta pemulihan informasi fitur pada segmentasi citra daun berpenyakit (Zhang & Zhang, 2023). Pada citra daun kentang, pengembangan model berbasis U-Net dengan penggunaan ResNet50 dan mekanisme *squeeze-and-excitation* dilakukan untuk meningkatkan kemampuan model dalam mengenali bercak penyakit yang berukuran kecil (Fu et al., 2023). Pendekatan *Cascading Autoencoder with Attention Residual U-Net* juga dikembangkan untuk melakukan segmentasi dan klasifikasi penyakit daun pada tingkat piksel dengan mempertahankan informasi fitur dan batas objek (Abinaya et al., 2023). Berbagai pengembangan tersebut menunjukkan bahwa modifikasi arsitektur dapat diarahkan untuk mengatasi karakteristik khusus pada citra tanaman, terutama ketika objek penyakit memiliki ukuran kecil, bentuk tidak beraturan, atau batas yang kurang tegas.

Meskipun berbagai modifikasi U-Net telah menunjukkan potensi pada segmentasi penyakit tanaman, penggunaan model yang semakin kompleks tidak secara otomatis menjamin kesesuaian model untuk setiap jenis tanaman dan dataset. Perbedaan kondisi citra, jenis tanaman, ukuran area penyakit, karakteristik daun, serta kondisi pengambilan gambar dapat memengaruhi hasil segmentasi yang diperoleh (Ngugi et al., 2021). Penelitian mengenai pengenalan penyakit pada kondisi lapangan juga menunjukkan bahwa performa model yang diperoleh pada citra dengan kondisi terkontrol dapat mengalami perubahan ketika diterapkan pada citra dengan kondisi lingkungan yang lebih beragam (Gui et al., 2021). Oleh sebab itu, evaluasi terhadap model U-Net pada dataset

dan objek tanaman tertentu tetap diperlukan untuk mengetahui kemampuan segmentasi secara spesifik.

Dalam konteks tanaman kakao, teknologi berbasis *Deep Learning* telah mulai diterapkan untuk mendukung proses deteksi penyakit. Pendekatan berbasis CNN telah digunakan untuk mengembangkan aplikasi *smartphone* yang membantu mendeteksi penyakit kakao berdasarkan citra tanaman, menunjukkan potensi penerapan teknologi pembelajaran mendalam dalam mendukung diagnosis penyakit kakao (Kumi et al., 2022). Selain pendekatan klasifikasi atau deteksi, informasi spasial pada citra juga penting karena luas dan distribusi area penyakit dapat menjadi informasi tambahan dalam analisis kondisi tanaman (Isabela & Muzakkar, 2026). Penerapan *deep semantic segmentation* pada citra daun anggur menunjukkan bahwa segmentasi pada tingkat piksel dapat digunakan untuk mengkuantifikasi distribusi penyakit pada permukaan daun (Liu et al., 2022). Pendekatan segmentasi semantik pada daun tanaman juga telah dikembangkan untuk menghasilkan representasi area daun yang dapat digunakan sebagai tahap pendukung dalam klasifikasi penyakit (Khan et al., 2022). Dengan demikian, segmentasi dapat ditempatkan sebagai salah satu tahapan penting dalam pengembangan sistem analisis penyakit kakao berbasis citra, terutama ketika informasi mengenai lokasi dan luas area yang terindikasi mengalami gangguan diperlukan.

Berdasarkan penelitian terdahulu, terdapat bukti bahwa segmentasi berbasis *Deep Learning* dapat digunakan untuk memisahkan objek tanaman, daun, maupun area penyakit pada tingkat piksel. Namun, karakteristik citra dan gejala penyakit berbeda antarspesies tanaman sehingga hasil penelitian pada tanaman lain tidak dapat secara langsung digunakan untuk merepresentasikan kemampuan model pada daun kakao. Kajian mengenai penyakit kakao menunjukkan bahwa tanaman ini menghadapi beragam patogen dengan karakteristik dan mekanisme penyakit yang berbeda (de Novais et al., 2023). Selain itu, penyakit seperti *vascular streak dieback* juga telah dilaporkan sebagai salah satu penyakit penting pada kakao di Indonesia, sehingga pemantauan kondisi tanaman menjadi relevan dalam konteks produksi kakao nasional (Rosmana et al., 2019). Kondisi tersebut menunjukkan perlunya penelitian yang secara khusus menguji kemampuan metode segmentasi pada citra daun kakao.

Penelitian ini mengisi kebutuhan tersebut dengan menerapkan *Deep Learning* berbasis arsitektur U-Net untuk melakukan segmentasi citra daun kakao. Data yang digunakan berupa citra digital daun kakao dalam kondisi sehat dan terindikasi mengalami gangguan yang diperoleh dari sumber data terbuka, disertai *ground-truth mask* sebagai acuan segmentasi pada tingkat piksel. Tahapan pengolahan data mencakup *resize*, normalisasi nilai piksel, pembentukan *binary mask*, dan pembagian dataset menjadi data *training*, *validation*, dan *testing*. Pendekatan segmentasi berbasis U-Net kemudian digunakan untuk menghasilkan pemisahan area daun dari latar belakang, sedangkan hasil segmentasi dianalisis lebih lanjut untuk mendukung identifikasi area yang terindikasi mengalami penyakit. Evaluasi dilakukan menggunakan *Accuracy*, *Intersection over Union* (IoU), dan *Dice Coefficient* untuk mengukur kesesuaian hasil prediksi dengan *ground-truth mask*. Penggunaan metrik tersebut sejalan dengan penelitian segmentasi daun yang mengevaluasi ketepatan pemisahan objek menggunakan ukuran kesesuaian pada tingkat piksel (Chowdhury et al., 2021).

Kontribusi penelitian ini terletak pada penerapan dan evaluasi U-Net standar pada citra daun kakao sebagai tahap awal pengembangan sistem deteksi penyakit tanaman

berbasis *Computer Vision*. Berbeda dengan penelitian yang mengembangkan berbagai modifikasi U-Net untuk meningkatkan kompleksitas ekstraksi fitur, penelitian ini berfokus pada pengujian kemampuan arsitektur U-Net dasar pada karakteristik dataset daun kakao tertentu (Zhang & Zhang, 2023). Fokus segmentasi pada tingkat piksel juga memungkinkan hasil prediksi tidak hanya digunakan untuk memisahkan objek daun dari latar belakang, tetapi dapat menjadi dasar untuk analisis spasial pada tahap berikutnya (Khan et al., 2022). Pendekatan tersebut diharapkan dapat memberikan gambaran mengenai kemampuan U-Net dalam menghasilkan segmentasi citra daun kakao yang konsisten dengan *ground truth*.

Dengan demikian, penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi model *Deep Learning* berbasis arsitektur U-Net dalam melakukan segmentasi citra daun kakao untuk mendukung deteksi dini penyakit tanaman. Evaluasi dilakukan berdasarkan kemampuan model dalam menghasilkan segmentasi pada tingkat piksel menggunakan *Accuracy*, IoU, dan Dice Coefficient. Hasil segmentasi selanjutnya digunakan sebagai dasar untuk menganalisis area daun yang terindikasi mengalami penyakit. Pendekatan berbasis segmentasi tersebut diharapkan dapat menjadi salah satu tahapan dalam pengembangan sistem deteksi penyakit kakao yang lebih terstruktur, terukur, dan berbasis informasi spasial.

Metode

Desain dan Tahapan Penelitian

Penelitian ini menggunakan pendekatan eksperimental untuk mengimplementasikan metode deep learning berbasis arsitektur U-Net dalam melakukan segmentasi citra daun kakao. Penelitian dilakukan melalui beberapa tahapan yang meliputi pengumpulan dan persiapan data, prapemrosesan citra dan mask, pembagian dataset, perancangan dan pelatihan model U-Net, pengujian model menggunakan data yang belum pernah digunakan selama pelatihan, serta evaluasi hasil segmentasi. Alur penelitian disusun untuk memperoleh model yang mampu menghasilkan segmentasi objek daun secara otomatis dan selanjutnya digunakan untuk menganalisis area yang terindikasi mengalami penyakit.

Data dan Objek Penelitian

Data yang digunakan berupa citra digital daun kakao yang diperoleh dari dataset terbuka. Dataset terdiri atas citra daun kakao yang digunakan sebagai data masukan serta citra mask segmentasi sebagai target model. Setiap citra masukan dipasangkan dengan mask yang sesuai agar hubungan antara citra dan target segmentasi tetap terjaga selama proses pelatihan. Mask digunakan sebagai representasi area objek yang menjadi target segmentasi pada citra daun kakao. Penggunaan pasangan citra dan mask memungkinkan model U-Net mempelajari hubungan antara karakteristik visual citra dengan bentuk area segmentasi yang diharapkan.

Prapemrosesan dan Pembagian Dataset

Tahap prapemrosesan dilakukan untuk menyeragamkan bentuk dan nilai data sebelum digunakan dalam proses pelatihan. Citra masukan diubah ukurannya menjadi 224 × 224 piksel, kemudian nilai piksel dinormalisasi ke dalam rentang 0–1. Sementara itu, mask segmentasi dikonversi menjadi citra biner dengan nilai 0 merepresentasikan latar

belakang dan nilai 1 merepresentasikan area daun. Tahapan tersebut menghasilkan citra dan mask dengan ukuran serta format yang seragam sehingga dapat digunakan sebagai pasangan input dan target pada model U-Net.

Setelah prapemrosesan, dataset dibagi menjadi tiga kelompok, yaitu data training sebesar 80%, data validation sebesar 10%, dan data testing sebesar 10%. Pembagian dilakukan menggunakan fungsi train_test_split dari pustaka Scikit-learn. Proses dilakukan dalam dua tahap, yaitu membagi dataset awal menjadi 80% data training dan 20% data sementara, kemudian data sementara dibagi kembali menjadi masing-masing 10% data validation dan 10% data testing. Nilai random_state = 42 digunakan agar pembagian data dapat direproduksi pada proses berikutnya. Data training digunakan untuk pembelajaran model, data validation untuk memantau kinerja model selama pelatihan, sedangkan data testing digunakan untuk mengukur kemampuan model terhadap data yang belum digunakan selama proses pembelajaran.

Perancangan dan Pelatihan Model U-Net

Model segmentasi yang digunakan adalah arsitektur U-Net, yang terdiri atas bagian encoder dan decoder. Encoder digunakan untuk mengekstraksi fitur dari citra masukan melalui proses konvolusi dan pooling, sedangkan decoder digunakan untuk mengembalikan resolusi fitur hingga menghasilkan keluaran segmentasi. Arsitektur U-Net juga menggunakan skip connection untuk mempertahankan informasi spasial yang diperoleh pada bagian encoder sehingga detail objek dapat dipertahankan pada hasil segmentasi.

Model menerima citra daun berukuran 224 × 224 piksel sebagai masukan dan menghasilkan mask segmentasi sebagai keluaran. Proses pelatihan menggunakan optimizer Adam dengan fungsi loss Binary Crossentropy. Model dilatih selama 10 epoch dengan ukuran batch sebesar 8. Data validation digunakan selama proses pelatihan untuk memantau perubahan performa model pada data yang tidak digunakan sebagai data pembelajaran langsung. Konfigurasi tersebut digunakan untuk memperoleh model yang dapat mempelajari pola segmentasi dari pasangan citra dan mask yang tersedia.

Pengujian dan Hasil Segmentasi

Setelah proses pelatihan selesai, model diuji menggunakan data testing yang tidak dilibatkan dalam proses pembelajaran maupun validasi. Tahap pengujian dilakukan dengan memberikan citra masukan kepada model untuk menghasilkan mask prediksi. Mask hasil prediksi kemudian dibandingkan secara visual dengan mask target untuk melihat kemampuan model dalam mempertahankan bentuk dan area objek daun.

Selain perbandingan visual, hasil prediksi digunakan untuk memperoleh informasi mengenai area yang terindikasi pada citra daun. Analisis tersebut dilakukan berdasarkan hasil segmentasi sehingga dapat diketahui proporsi area tertentu terhadap keseluruhan area daun pada citra uji. Salah satu hasil pengujian kemudian digunakan untuk menghitung persentase area terindikasi penyakit sebagai bagian dari analisis deteksi dini.

Evaluasi Kinerja Model

Evaluasi dilakukan untuk mengukur kesesuaian antara hasil segmentasi yang dihasilkan model dengan *mask* target. Tiga metrik digunakan dalam penelitian ini, yaitu *Accuracy*, *Intersection over Union* (IoU), dan *Dice Coefficient*. Perhitungan metrik evaluasi didasarkan pada nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False*

Negative (FN), yang diperoleh dari perbandingan antara hasil prediksi model dan *ground-truth mask*.

Accuracy digunakan untuk mengetahui proporsi piksel yang berhasil diprediksi dengan benar terhadap keseluruhan piksel. Nilai *Accuracy* dihitung menggunakan persamaan:

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

Intersection over Union (IoU) digunakan untuk mengukur tingkat tumpang tindih antara area hasil prediksi dan area pada *mask* target. IoU dihitung berdasarkan perbandingan antara area irisan (*intersection*) dan area gabungan (*union*) dari hasil prediksi dan *ground-truth mask*, sebagaimana ditunjukkan pada persamaan berikut:

$$IoU = \frac{TP}{(TP + FP + FN)}$$

Dice Coefficient digunakan untuk mengukur tingkat kesamaan antara area hasil prediksi dan *mask* target. Nilai Dice memberikan ukuran kesamaan berdasarkan jumlah piksel yang berhasil diprediksi sebagai objek pada kedua citra, sebagaimana persamaan berikut:

$$Dice = \frac{(2 \times TP)}{(2 \times TP + FP + FN)}$$

Dalam persamaan tersebut, TP (*True Positive*) merupakan jumlah piksel objek yang berhasil diprediksi sebagai objek, TN (*True Negative*) merupakan jumlah piksel latar belakang yang berhasil diprediksi sebagai latar belakang, FP (*False Positive*) merupakan jumlah piksel latar belakang yang diprediksi sebagai objek, sedangkan FN (*False Negative*) merupakan jumlah piksel objek yang diprediksi sebagai latar belakang. Nilai setiap metrik berada pada rentang 0 hingga 1, atau dapat dinyatakan dalam bentuk persentase. Semakin tinggi nilai *Accuracy*, IoU, dan Dice, semakin tinggi tingkat kesesuaian hasil segmentasi terhadap *ground-truth mask*.

Selain evaluasi secara kuantitatif, dilakukan pula evaluasi visual dengan membandingkan citra masukan, *mask* hasil prediksi, dan hasil visualisasi segmentasi untuk mengamati ketepatan model dalam mempertahankan bentuk objek dan batas area segmentasi.

Lingkungan Implementasi

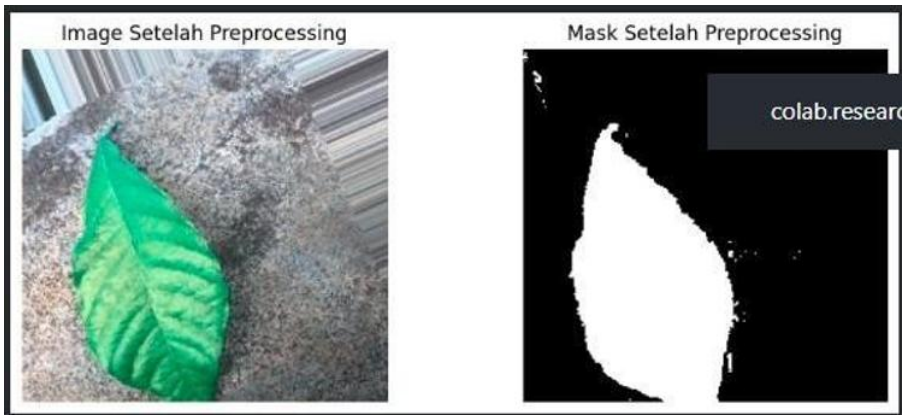
Implementasi penelitian dilakukan menggunakan bahasa pemrograman Python pada lingkungan Google Colab. Pengolahan citra dan data dilakukan menggunakan pustaka yang mendukung kebutuhan penelitian, termasuk *TensorFlow* untuk pembangunan dan pelatihan model deep learning, OpenCV untuk pengolahan citra, NumPy untuk manipulasi data numerik, serta Matplotlib untuk visualisasi hasil. Lingkungan komputasi berbasis Google Colab digunakan untuk mendukung proses pelatihan dan pengujian model U-Net.

Hasil

Hasil Visualisasi Citra dan Preprocessing

Tahap awal penelitian menghasilkan citra dan mask segmentasi yang telah disiapkan sebagai masukan bagi model U-Net. Citra masukan berupa citra daun kakao, sedangkan

mask segmentasi digunakan sebagai label untuk menunjukkan area objek yang menjadi target segmentasi. Pada tahap *preprocessing*, citra diubah ukurannya menjadi 224 × 224 piksel, nilai piksel dinormalisasi ke dalam rentang 0–1, dan mask dikonversi menjadi citra biner. Proses tersebut dilakukan untuk menyeragamkan format data sebelum digunakan dalam pelatihan model.

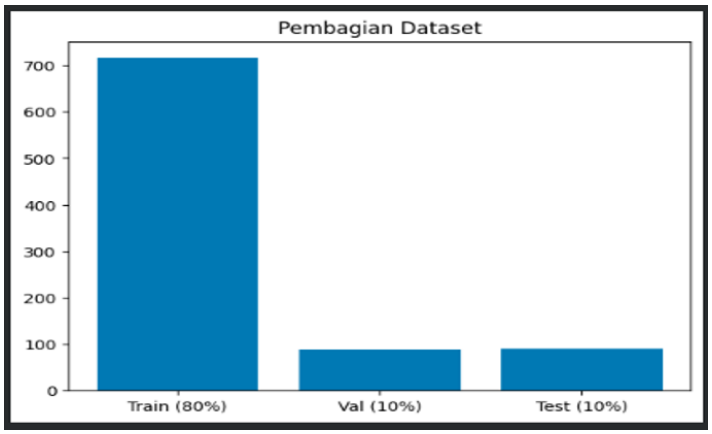


Gambar 1. *Preprocessing Citra dan Mask Segmentasi Daun Kakao*

Gambar 1 memperlihatkan hasil preprocessing citra dan *mask* sebelum digunakan dalam proses pelatihan. Citra telah memiliki ukuran yang seragam, sedangkan mask segmentasi direpresentasikan dalam bentuk biner dengan area objek dan latar belakang yang dapat dibedakan. Hasil *preprocessing* menunjukkan bahwa citra dan mask telah berada dalam format yang sesuai untuk digunakan sebagai pasangan data masukan dan label pada model U-Net.

Hasil Pembagian Dataset

Setelah proses preprocessing, dataset dibagi menjadi tiga subset, yaitu data pelatihan (*training*), data validasi (*validation*), dan data pengujian (*testing*). Pembagian dilakukan menggunakan fungsi train_test_split dari pustaka Scikit-Learn dengan rasio 80%:10%:10%. Pembagian dilakukan secara bertahap, yaitu 80% data digunakan untuk pelatihan, sedangkan 20% data sementara selanjutnya dibagi menjadi data validasi dan data pengujian dengan proporsi yang sama. Nilai random_state = 42 digunakan agar pembagian dataset dapat direproduksi.



Gambar 2. *Pembagian Dataset*

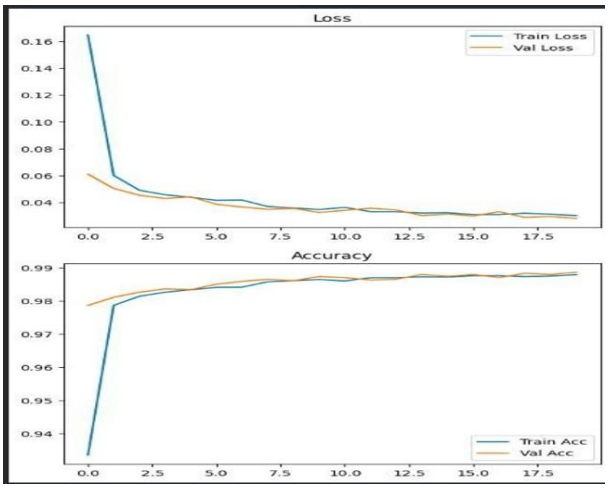
Gambar 2 menunjukkan hasil pembagian dataset yang digunakan dalam eksperimen. Data *training* digunakan untuk proses pembelajaran model U-Net, data *validation*

digunakan untuk memantau performa model selama proses pelatihan, sedangkan data *testing* digunakan untuk mengukur kemampuan model terhadap data yang tidak digunakan dalam proses pembelajaran. Pembagian tersebut memberikan proporsi data yang lebih besar pada proses pelatihan sehingga model memiliki lebih banyak data untuk mempelajari karakteristik citra daun kakao.

Hasil Pelatihan Model U-Net

Model U-Net kemudian dilatih menggunakan dataset yang telah dipersiapkan. Arsitektur U-Net terdiri atas bagian *encoder* dan *decoder*. Bagian *encoder* digunakan untuk mengekstraksi karakteristik citra melalui proses *convolution* dan *max pooling*, sedangkan bagian *decoder* digunakan untuk mengembalikan resolusi citra hingga menghasilkan keluaran segmentasi.

Proses pelatihan menggunakan optimizer Adam dengan *loss function* Binary Crossentropy. Pelatihan dilakukan selama 10 *epoch* dengan *batch size* sebesar 8. Konfigurasi tersebut digunakan untuk melakukan pembelajaran terhadap pola segmentasi citra daun kakao.

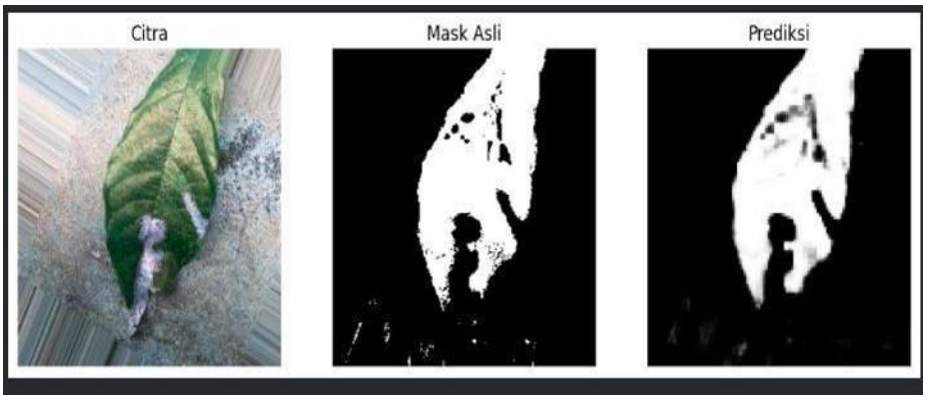


Gambar 3. *Grafik Perubahan Accuracy dan Loss selama Pelatihan Model U-Net*

Gambar 3 memperlihatkan perkembangan performa model selama proses pelatihan. Berdasarkan grafik, nilai *accuracy* mengalami peningkatan pada setiap *epoch*, sedangkan nilai *loss* menunjukkan kecenderungan menurun. Pola tersebut menunjukkan bahwa model memperoleh pembelajaran dari data pelatihan dan semakin mampu mengenali pola segmentasi yang diberikan. Hasil pelatihan ini menjadi dasar untuk tahap pengujian menggunakan data yang telah dipisahkan sebagai data uji.

Hasil Segmentasi Citra Daun Kakao

Setelah proses pelatihan selesai, model U-Net digunakan untuk melakukan prediksi terhadap citra pada data pengujian dan citra yang digunakan untuk visualisasi hasil segmentasi. Hasil segmentasi berupa mask prediksi digunakan untuk menunjukkan area objek daun yang berhasil dikenali oleh model.



Gambar 4. *Segmentasi Citra Daun Kakao Menggunakan Model U-Net*

Gambar 4 menunjukkan bahwa model mampu memisahkan area daun dari latar belakang pada sebagian besar citra yang diuji. Bentuk utama dan kontur daun dapat dipertahankan, meskipun masih ditemukan beberapa kesalahan segmentasi pada bagian tepi objek. Hasil tersebut menunjukkan bahwa U-Net mampu menghasilkan mask segmentasi yang cukup detail dalam mengenali objek daun. Visualisasi ini juga menjadi dasar untuk tahap berikutnya, yaitu pemanfaatan hasil segmentasi dalam proses identifikasi awal area yang terindikasi penyakit.

Hasil Deteksi Area Terindikasi Penyakit

Hasil segmentasi selanjutnya digunakan untuk memperoleh informasi mengenai area daun yang terindikasi mengalami penyakit. Pada pengujian terhadap salah satu citra daun kakao, sistem menghasilkan tiga bentuk keluaran, yaitu citra asli, mask hasil prediksi, dan *overlay*. Citra asli digunakan sebagai masukan, mask prediksi menunjukkan hasil segmentasi dalam bentuk citra biner, sedangkan *overlay* digunakan untuk memperlihatkan hasil segmentasi pada citra asli.



Gambar 5*. Hasil Deteksi Area Terindikasi Penyakit pada Citra Daun Kakao*

Gambar 5 memperlihatkan hasil deteksi menggunakan model U-Net pada salah satu citra daun kakao dari data uji. Hasil perhitungan menunjukkan bahwa luas area yang terindikasi penyakit mencapai 20,33% dari keseluruhan luas permukaan daun. Berdasarkan persentase tersebut, sistem mengelompokkan tingkat serangan ke dalam kategori serangan sedang. Hasil ini menunjukkan bahwa keluaran segmentasi dapat dimanfaatkan untuk memperoleh informasi kuantitatif mengenai luas area yang terindikasi mengalami penyakit.

Hasil Evaluasi Kinerja Model

Evaluasi dilakukan untuk mengetahui tingkat kesesuaian antara hasil segmentasi model dengan *ground truth*. Evaluasi menggunakan tiga metrik, yaitu Pixel Accuracy, *Intersection over Union* (IoU), dan *Dice Coefficient*. Ketiga metrik tersebut digunakan untuk mengukur kesesuaian area hasil prediksi dengan area yang terdapat pada mask sebenarnya.

Tabel 1. *Hasil Evaluasi Kinerja Model U-Net*

Metrik	Nilai
Accuracy	98%
Intersection over Union (IoU)	91%
Dice Coefficient	94%

Berdasarkan Tabel 1, model U-Net memperoleh Accuracy sebesar 98%, IoU sebesar 91%, dan Dice Coefficient sebesar 94%. Nilai tersebut menunjukkan tingkat kesesuaian yang tinggi antara hasil prediksi segmentasi dan *ground truth* pada data pengujian. Nilai Accuracy menunjukkan proporsi piksel yang berhasil diprediksi dengan benar, sedangkan IoU dan Dice menunjukkan tingkat tumpang tindih antara area hasil prediksi dengan area pada *ground truth*. Hasil evaluasi tersebut konsisten dengan hasil visualisasi yang menunjukkan bahwa model mampu mempertahankan bentuk utama objek daun dan menghasilkan mask yang mendekati kondisi sebenarnya. Nilai *Accuracy*, IoU, dan Dice tersebut juga merupakan metrik utama yang dilaporkan dalam abstrak penelitian.

Pembahasan

Kinerja Preprocessing dan Pembagian Dataset

Hasil *preprocessing* menunjukkan bahwa citra masukan dan *mask* segmentasi berhasil diseragamkan sebelum digunakan dalam proses pelatihan. Penyesuaian ukuran menjadi 224 × 224 piksel memberikan format input yang konsisten bagi model U-Net, sedangkan normalisasi nilai piksel ke rentang 0–1 menghasilkan representasi data yang lebih terstandar. Konversi *mask* menjadi citra biner juga memberikan target segmentasi yang jelas, dengan nilai 0 untuk latar belakang dan nilai 1 untuk area objek daun. Kondisi tersebut penting dalam proses pembelajaran segmentasi karena model memerlukan pasangan citra masukan dan target yang memiliki ukuran serta representasi yang konsisten. Tahapan prapemrosesan yang tepat merupakan bagian penting dalam pengembangan sistem analisis penyakit tanaman berbasis citra karena kualitas dan konsistensi data masukan dapat memengaruhi proses pembelajaran model (Ngugi et al., 2021; Sinha & Shekhawat, 2020). Hasil *preprocessing* yang seragam menjadi dasar bagi tahapan pelatihan dan pengujian model.

Pembagian dataset dengan proporsi 80% data *training*, 10% *validation*, dan 10% *testing* memberikan porsi terbesar kepada data yang digunakan untuk pembelajaran model. Data *validation* digunakan untuk memantau proses pembelajaran selama *training*, sedangkan data *testing* digunakan untuk mengetahui kemampuan model pada data yang tidak digunakan dalam proses pembelajaran. Penggunaan *random_state* = 42 juga membuat proses pembagian data dapat direproduksi. Dengan demikian, evaluasi pada data *testing* dapat digunakan untuk memberikan gambaran mengenai kemampuan model dalam melakukan segmentasi terhadap data yang belum dilihat sebelumnya. Pendekatan pembagian data ini sejalan dengan prinsip evaluasi model *Deep Learning* yang

memisahkan data pembelajaran dan data pengujian untuk menilai kemampuan model terhadap data yang tidak digunakan selama proses pelatihan (Ferentinos, 2018). Pendekatan tersebut tidak hanya mengukur kemampuan model dalam mempelajari data *training*, tetapi juga mengamati kemampuan model menghasilkan segmentasi pada data uji.

Kemampuan Model U-Net dalam Mempelajari Pola Segmentasi

Hasil pelatihan menunjukkan adanya peningkatan nilai accuracy dan penurunan nilai loss selama epoch berlangsung. Pola tersebut menunjukkan bahwa model secara bertahap mempelajari hubungan antara citra daun sebagai input dengan mask segmentasi sebagai target. Penurunan loss menunjukkan bahwa perbedaan antara hasil prediksi model dan target segmentasi semakin kecil selama proses pembelajaran, sedangkan peningkatan accuracy menunjukkan semakin banyak piksel yang dapat diprediksi sesuai dengan target.

Penggunaan arsitektur U-Net mendukung proses tersebut karena model memiliki mekanisme *encoder-decoder* yang memungkinkan ekstraksi fitur sekaligus pemulihan informasi spasial. Pada proses segmentasi objek daun, informasi spasial diperlukan untuk mempertahankan bentuk dan kontur objek. *Skip connection* pada U-Net memungkinkan informasi dari bagian *encoder* diteruskan ke *decoder* sehingga detail spasial yang diperlukan dalam menghasilkan *mask* dapat dipertahankan. Karakteristik tersebut menjadi salah satu alasan U-Net banyak digunakan untuk permasalahan segmentasi yang membutuhkan pemulihan informasi spasial secara detail, termasuk pada citra tanaman dan daun (Chowdhury et al., 2021; Sodjinou et al., 2022). Hal tersebut sesuai dengan hasil pengujian visual yang menunjukkan bahwa bentuk utama daun dapat dipertahankan meskipun masih terdapat kesalahan pada beberapa bagian tepi objek.

Konfigurasi pelatihan menggunakan Adam, *Binary Crossentropy*, 10 *epoch*, dan *batch size* 8 menghasilkan proses pembelajaran yang dapat digunakan untuk membentuk model segmentasi. Namun, peningkatan *accuracy* dan penurunan *loss* selama *training* tidak dapat digunakan secara tunggal untuk menyatakan bahwa model telah memiliki kemampuan generalisasi yang tinggi. Oleh karena itu, hasil pelatihan perlu dipertimbangkan bersama hasil pengujian pada data *testing* dan metrik segmentasi yang digunakan dalam penelitian. Penggunaan data pengujian yang terpisah diperlukan untuk mengetahui kemampuan model ketika berhadapan dengan citra yang tidak digunakan selama pembelajaran (Ferentinos, 2018).

Kualitas Hasil Segmentasi Citra Daun Kakao

Hasil pengujian menunjukkan bahwa model U-Net mampu memisahkan area daun dari latar belakang pada sebagian besar citra uji. Secara visual, bentuk utama daun dapat dipertahankan dan hasil *mask* mengikuti kontur objek dengan cukup baik. Hal ini menunjukkan bahwa model berhasil mempelajari karakteristik visual yang membedakan objek daun dengan latar belakang. Kemampuan segmentasi pada tingkat piksel memungkinkan informasi spasial objek tanaman dipertahankan sehingga hasil segmentasi dapat digunakan untuk analisis lebih lanjut (Khan et al., 2022).

Meskipun demikian, hasil segmentasi masih menunjukkan kesalahan pada bagian tepi objek. Kesalahan tersebut menunjukkan bahwa model belum sepenuhnya mampu mempertahankan batas objek pada seluruh bagian citra. Area tepi merupakan bagian

yang relatif penting dalam segmentasi karena perubahan antara objek dan latar belakang terjadi pada batas tersebut. Ketidaktepatan pada bagian ini dapat menyebabkan sebagian piksel objek tidak tersegmentasi atau sebagian piksel latar belakang ikut diprediksi sebagai objek. Permasalahan pada batas objek juga dapat menjadi lebih kompleks pada citra tanaman karena variasi bentuk, warna, tekstur, pencahayaan, dan kondisi latar belakang dapat memengaruhi proses segmentasi (Ngugi et al., 2021).

Temuan tersebut juga menunjukkan bahwa nilai evaluasi yang diperoleh perlu dipahami bersama hasil visualisasi. Nilai metrik yang tinggi memberikan gambaran kuantitatif mengenai kesesuaian prediksi secara keseluruhan, tetapi visualisasi tetap diperlukan untuk mengetahui lokasi kesalahan segmentasi. Dengan demikian, kombinasi evaluasi kuantitatif dan visual memberikan gambaran yang lebih lengkap mengenai kinerja U-Net pada citra daun kakao.

Interpretasi Hasil Deteksi Area Terindikasi Penyakit

Hasil pengujian lebih lanjut menunjukkan bahwa segmentasi dapat digunakan sebagai dasar untuk menghitung proporsi area yang terindikasi pada citra daun. Pada salah satu citra uji, area yang terindikasi penyakit mencapai 20,33% dari keseluruhan luas permukaan daun dan dalam penelitian dikategorikan sebagai serangan sedang. Hasil tersebut menunjukkan bahwa keluaran segmentasi dapat dikembangkan menjadi informasi kuantitatif mengenai kondisi permukaan daun, bukan hanya berupa visualisasi *mask*. Pendekatan segmentasi pada tingkat piksel juga telah digunakan untuk memperoleh informasi mengenai distribusi dan luas area penyakit pada citra daun tanaman (Liu et al., 2022).

Namun, interpretasi tersebut perlu ditempatkan dalam ruang lingkup penelitian. Model U-Net yang digunakan dalam eksperimen utama melakukan segmentasi objek daun berdasarkan *mask*, sedangkan informasi mengenai area terindikasi penyakit diperoleh dari hasil analisis terhadap keluaran segmentasi. Oleh karena itu, hasil 20,33% lebih tepat dipahami sebagai informasi hasil analisis pada citra uji yang digunakan, bukan sebagai ukuran performa model secara keseluruhan.

Selain itu, penelitian ini tidak melakukan klasifikasi jenis penyakit secara spesifik. Dengan demikian, keluaran sistem belum dapat digunakan untuk menyatakan jenis penyakit tertentu. Informasi yang dihasilkan lebih berfungsi sebagai indikasi awal kondisi daun dan sebagai dasar untuk pengembangan sistem deteksi penyakit yang lebih lengkap. Batasan ini penting karena keberhasilan segmentasi objek daun tidak secara langsung menunjukkan bahwa seluruh jenis penyakit pada daun dapat dikenali secara otomatis. Pengembangan sistem analisis penyakit pada tahap berikutnya dapat menggabungkan segmentasi dengan klasifikasi sehingga informasi spasial dan karakteristik penyakit dapat dianalisis secara bersama-sama (Abinaya et al., 2023).

Evaluasi Kinerja Model Berdasarkan Accuracy, IoU, dan Dice

Evaluasi kuantitatif menghasilkan nilai *Accuracy* sebesar 98%, IoU sebesar 91%, dan *Dice Coefficient* sebesar 94%. Ketiga metrik tersebut menunjukkan tingkat kesesuaian yang tinggi antara hasil prediksi segmentasi dan target yang digunakan dalam evaluasi. Nilai *Accuracy* sebesar 98% menunjukkan bahwa sebagian besar piksel berhasil diprediksi sesuai dengan target. Sementara itu, nilai IoU sebesar 91% dan Dice sebesar 94% menunjukkan tingkat tumpang tindih yang tinggi antara area hasil prediksi dan area pada

ground truth. Penggunaan IoU dan Dice merupakan pendekatan yang umum digunakan dalam mengevaluasi kualitas segmentasi karena kedua metrik tersebut mempertimbangkan kesesuaian area prediksi terhadap area target (Khan et al., 2022).

Perbedaan antara nilai *Accuracy*, IoU, dan Dice juga menunjukkan pentingnya menggunakan lebih dari satu metrik dalam mengevaluasi model segmentasi. *Accuracy* memberikan gambaran mengenai ketepatan piksel secara keseluruhan, sedangkan IoU dan Dice lebih berfokus pada kesesuaian area prediksi dengan area target. Dengan menggunakan ketiga metrik tersebut secara bersamaan, evaluasi tidak hanya bergantung pada jumlah piksel yang benar, tetapi juga mempertimbangkan tingkat tumpang tindih area segmentasi. Pendekatan evaluasi menggunakan beberapa metrik dapat memberikan gambaran yang lebih komprehensif mengenai kinerja model segmentasi pada citra tanaman (Chowdhury et al., 2021).

Meskipun hasil evaluasi menunjukkan performa yang tinggi, hasil tersebut tidak berarti bahwa model bebas dari kesalahan. Visualisasi pengujian masih memperlihatkan kesalahan pada bagian tepi objek. Selain itu, penelitian menggunakan dataset publik dengan jumlah dan variasi data yang terbatas, sehingga kemampuan model ketika diterapkan pada kondisi citra yang lebih beragam masih perlu diuji lebih lanjut. Variasi kondisi citra, termasuk perubahan pencahayaan, latar belakang, dan karakteristik visual objek, diketahui dapat menjadi tantangan dalam penerapan sistem pengenalan penyakit tanaman pada kondisi yang lebih beragam (Gui et al., 2021).

Implikasi dan Keterbatasan Penelitian

Secara keseluruhan, hasil penelitian menunjukkan bahwa U-Net dapat digunakan untuk melakukan segmentasi citra daun kakao dan menghasilkan *mask* yang cukup sesuai dengan target segmentasi. Kemampuan tersebut menjadikan segmentasi sebagai salah satu tahapan yang dapat mendukung pengembangan sistem analisis kondisi daun berbasis citra. Hasil segmentasi juga memungkinkan dilakukannya analisis lanjutan, seperti pengukuran luas area yang terindikasi. Pemanfaatan segmentasi semantik untuk memperoleh informasi spasial mengenai area tanaman telah diterapkan dalam berbagai penelitian berbasis citra tanaman (Sodjinou et al., 2022; Liu et al., 2022).

Namun, terdapat beberapa keterbatasan yang perlu diperhatikan. Kualitas dan jumlah dataset dapat memengaruhi kemampuan model dalam mengenali variasi citra yang lebih luas. Kesalahan pada bagian tepi juga menunjukkan bahwa ketepatan batas segmentasi masih dapat ditingkatkan. Selain itu, penelitian belum mencakup klasifikasi jenis penyakit sehingga keluaran sistem masih berada pada tahap segmentasi dan indikasi awal kondisi daun. Variasi lingkungan dan kondisi citra juga merupakan salah satu tantangan dalam penerapan model *Deep Learning* untuk deteksi penyakit tanaman di kondisi nyata (Gui et al., 2021).

Dengan demikian, hasil penelitian ini lebih tepat diposisikan sebagai dasar untuk pengembangan sistem deteksi penyakit tanaman berbasis citra secara lebih menyeluruh. Pengembangan berikutnya dapat diarahkan pada penggunaan dataset yang lebih besar dan beragam, peningkatan kualitas *preprocessing*, serta pengembangan arsitektur segmentasi yang lebih lanjut. Hasil segmentasi juga dapat diintegrasikan dengan tahap klasifikasi penyakit sehingga sistem tidak hanya mampu menunjukkan area yang terindikasi, tetapi juga dapat memberikan informasi mengenai jenis penyakit berdasarkan karakteristik area yang terdeteksi. Pendekatan integrasi antara segmentasi dan klasifikasi

pada tingkat piksel telah digunakan dalam penelitian penyakit daun dan dapat menjadi arah pengembangan penelitian selanjutnya (Abinaya et al., 2023).

Kesimpulan

Penelitian ini bertujuan menerapkan metode *deep learning* berbasis U-Net untuk melakukan segmentasi citra daun kakao sebagai tahap awal dalam mendukung deteksi dini penyakit tanaman. Permasalahan yang menjadi dasar penelitian adalah kebutuhan untuk memperoleh pemisahan area daun secara otomatis dan akurat dari citra sehingga informasi spasial pada citra dapat dianalisis lebih lanjut. Tahapan penelitian meliputi prapemrosesan citra, pembagian dataset, pelatihan model U-Net, pengujian pada data yang belum digunakan dalam pelatihan, serta evaluasi menggunakan *Accuracy*, *Intersection over Union* (IoU), dan *Dice Coefficient*.

Hasil penelitian menunjukkan bahwa model U-Net mampu melakukan segmentasi citra daun kakao dengan baik, ditunjukkan oleh nilai *Accuracy* sebesar 98%, IoU sebesar 91%, dan *Dice Coefficient* sebesar 94%. Hasil visualisasi juga menunjukkan bahwa model dapat memisahkan area daun dari latar belakang, meskipun masih terdapat kesalahan pada beberapa bagian tepi objek. Pada salah satu citra pengujian, analisis area menunjukkan bahwa bagian yang terindikasi mengalami penyakit sebesar 20,33% dari keseluruhan area daun dan dikategorikan sebagai serangan sedang.

Secara implikatif, hasil tersebut menunjukkan bahwa U-Net dapat digunakan sebagai pendekatan segmentasi yang mendukung proses analisis citra daun kakao untuk deteksi dini penyakit. Penelitian selanjutnya dapat dikembangkan dengan memperluas variasi dan jumlah dataset, meningkatkan kualitas anotasi dan segmentasi pada area tepi daun, serta mengintegrasikan hasil segmentasi dengan metode klasifikasi untuk mengidentifikasi jenis penyakit secara otomatis.

Acknowledgment

-

Daftar Pustaka

Abinaya, S., Kumar, K. U., & Alphonse, A. S. (2023). Cascading autoencoder with attention residual U-Net for multi-class plant leaf disease segmentation and classification. *IEEE Access, 11*, 98153–98170. https://doi.org/10.1109/ACCESS.2023.3312718

Bischoff, V., Farias, K., Menzen, J. P., & Pessin, G. (2021). Technological support for detection and prediction of plant diseases: A systematic mapping study. *Computers and Electronics in Agriculture, 181*, 105922. https://doi.org/10.1016/j.compag.2020.105922

Boulent, J., Foucher, S., Théau, J., & St-Charles, P.-L. (2019). Convolutional neural networks for the automatic identification of plant diseases. *Frontiers in Plant Science, 10*, 941. https://doi.org/10.3389/fpls.2019.00941

Chen, J., Chen, J., Zhang, D., Sun, Y., & Nanehkaran, Y. A. (2020). Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture, 173*, 105393. https://doi.org/10.1016/j.compag.2020.105393

Chen, S., Zhang, K., Zhao, Y., Sun, Y., Ban, W., Chen, Y., Zhuang, H., Zhang, X., Liu, J., & Yang, T. (2021). An approach for rice bacterial leaf streak disease segmentation and disease severity estimation. *Agriculture, 11*(5), 420. https://doi.org/10.3390/agriculture11050420

Chowdhury, M. E. H., Rahman, T., Khandakar, A., Ayari, M. A., Khan, A. U., Khan, M. S., Al-Emadi, N., Reaz, M. B. I., Islam, M. T., & Ali, S. H. M. (2021). Automatic and reliable leaf disease detection using deep learning techniques. *AgriEngineering, 3*(2), 294–312. https://doi.org/10.3390/agriengineering3020020

de Novais, D. P. S., Batista, T. M., Costa, E. A., & Pirovani, C. P. (2023). Genomic and pathogenicity mechanisms of the main *Theobroma cacao* L. eukaryotic pathogens: A systematic review. *Microorganisms, 11*(6), 1567. https://doi.org/10.3390/microorganisms11061567

Deng, Y., Xi, H., Zhou, G., Chen, A., Wang, Y., Li, L., & Hu, Y. (2023). An effective image-based tomato leaf disease segmentation method using MC-UNet. *Plant Phenomics, 5*, 0049. https://doi.org/10.34133/plantphenomics.0049

Díaz-Valderrama, J. R., Leiva-Espinoza, S. T., & Aime, M. C. (2020). The history of cacao and its diseases in the Americas. *Phytopathology, 110*(10), 1604–1619. https://doi.org/10.1094/PHYTO-05-20-0178-RVW

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture, 145*, 311–318. https://doi.org/10.1016/j.compag.2018.01.009

Fu, J., Zhao, Y., & Wu, G. (2023). Potato leaf disease segmentation method based on improved UNet. *Applied Sciences, 13*(20), 11179. https://doi.org/10.3390/app132011179

Gui, P., Dang, W., Zhu, F., & Zhao, Q. (2021). Towards automatic field plant disease recognition. *Computers and Electronics in Agriculture, 191*, 106523. https://doi.org/10.1016/j.compag.2021.106523

Isabela, I., & Muzakkar, M. (2026). Membangun Sistem Pakar Diagnosis Penyakit pada Tanaman Kelapa Sawit di Indragiri Hilir Berbasis Website. *Journal Artificial: Informatika Dan Sistem Informasi*, *4*(1), 13–25. https://doi.org/10.54065/artificial.966

Jagoret, P., Snoeck, D., Bouambi, E., Ngoran, A., & Nyassé, S. (2021). Rehabilitation and renovation of cocoa (*Theobroma cacao* L.) agroforestry systems: A review. *Agronomy for Sustainable Development, 41*, Article 60. https://doi.org/10.1007/s13593-021-00717-9

Kaur, S., Pandey, S., & Goel, S. (2019). Plants disease identification and classification through leaf images: A survey. *Archives of Computational Methods in Engineering, 26*(2), 507–530. https://doi.org/10.1007/s11831-018-9255-6

Khan, K., Khan, R. U., Albattah, W., & Qamar, A. M. (2022). End-to-end semantic leaf segmentation framework for plants disease classification. *Complexity, 2022*, 1168700. https://doi.org/10.1155/2022/1168700

Kumi, S., Kelly, D., Woodstuff, J., Lomotey, R. K., Orji, R., & Deters, R. (2022). Cocoa Companion: Deep learning-based smartphone application for cocoa disease

detection. *Procedia Computer Science, 203*, 87–94. https://doi.org/10.1016/j.procs.2022.07.013

Liu, E., Gold, K. M., Combs, D., Cadle-Davidson, L., & Jiang, Y. (2022). Deep semantic segmentation for the quantification of grape foliar diseases in the vineyard. *Frontiers in Plant Science, 13*, 978761. https://doi.org/10.3389/fpls.2022.978761

Liu, Y., Hu, L., Cao, Y., Tang, J., & Lei, B. (2021). Image segmentation for maize leaf disease based on U-Net. *Chinese Agricultural Science Bulletin, 37*(5), 88–95. https://doi.org/10.11924/j.issn.1000-6850.casb2020-0051

Marelli, J.-P., Guest, D. I., Bailey, B. A., Evans, H. C., Brown, J. K., Junaid, M., Barreto, R. W., Lisboa, D. O., & Puig, A. S. (2019). Chocolate under threat from old and new cacao diseases. *Phytopathology, 109*(8), 1331–1343. https://doi.org/10.1094/PHYTO-12-18-0477-RVW

Ngugi, L. C., Abelwahab, M., & Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition—A review. *Information Processing in Agriculture, 8*(1), 27–51. https://doi.org/10.1016/j.inpa.2020.04.004

Rayhan, M. A. (2026). Implementation of Naive Bayes and Support Vector Machine for SMS Spam Classification Using the SMS Spam Collection Dataset. *Journal Artificial: Informatika Dan Sistem Informasi*, *4*(2), 197–212. https://doi.org/10.54065/artificial.1249

Rosmana, A., Taufik, M., Asman, A., Jayanti, N. J., & Hakkar, A. A. (2019). Dynamic of vascular streak dieback disease incidence on susceptible cacao treated with composted plant residues and Trichoderma asperellum in field. *Agronomy, 9*(10), Article 650. https://doi.org/10.3390/agronomy9100650

Sinha, A., & Shekhawat, R. S. (2020). Review of image processing approaches for detecting plant diseases. *IET Image Processing, 14*, 1427–1439. https://doi.org/10.1049/iet-ipr.2018.6210

Sodjinou, S. G., Mohammadi, V., Mahama, A. T. S., & Gouton, P. (2022). A deep semantic segmentation-based algorithm to segment crops and weeds in agronomic color images. *Information Processing in Agriculture, 9*(3), 355–364. https://doi.org/10.1016/j.inpa.2021.08.003

Wickramasuriya, A. M., & Dunwell, J. M. (2018). Cacao biotechnology: Current status and future prospects. *Plant Biotechnology Journal, 16*(1), 4–17. https://doi.org/10.1111/pbi.12848

Zhang, S., & Zhang, C. (2023). Modified U-Net for plant diseased leaf image segmentation. *Computers and Electronics in Agriculture, 204*, 107511. https://doi.org/10.1016/j.compag.2022.107511

Zhu, S., Ma, W., Lu, J., Ren, B., Wang, C., & Wang, J. (2023). A novel approach for apple leaf disease image segmentation in complex scenes based on two-stage DeepLabv3+ with adaptive loss. *Computers and Electronics in Agriculture, 204*, 107539. https://doi.org/10.1016/j.compag.2022.107539