

Penerapan Arsitektur U-Net pada Segmentasi Cacat Biji Kopi untuk Optimalisasi Inspeksi Kualitas

Implementation of U-Net Architecture for Coffee Bean Defect Segmentation to Optimize Quality Inspection

Ami Rahmawati*¹, Ita Yulianti², Ani Oktarini Sari³, Siti Nurajizah⁴

^{1,3}Fakultas Teknologi Informasi, Universitas Nusa Mandiri

^{2,4}Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

E-mail: 1ami.amv@nusamandiri.ac.id, 2ita.iyi@bsi.ac.id, 3ani.aos@nusamandiri.ac.id,
4siti.snz@bsi.ac.id

Abstrak

Identifikasi cacat pada biji kopi secara visual-manual masih rentan terhadap subjektivitas dan inkonsistensi penilaian, sehingga diperlukan pendekatan yang lebih akurat dan efisien. Penelitian ini mengusulkan metode segmentasi citra biji kopi berbasis deep learning menggunakan arsitektur U-Net untuk mendeteksi keberadaan cacat pada biji kopi secara umum menggunakan pendekatan binary segmentation. Dataset terdiri dari 300 citra biji kopi yang terbagi seimbang menjadi 150 citra kelas black coffee dan 150 citra kelas insect damage. Proses anotasi dilakukan menggunakan metode pseudo-labeling semi-otomatis berbasis Gaussian filtering, absolute difference, dan thresholding untuk menghasilkan ground truth mask dalam format binary mask. Data latih diperkaya melalui augmentasi berupa horizontal flip, vertical flip, rotasi, serta penyesuaian brightness dan contrast. Model dilatih menggunakan fungsi loss gabungan Dice Loss dan Binary Cross-Entropy dengan optimizer Adam selama 15 epoch dan mekanisme early stopping. Hasil evaluasi menunjukkan performa yang sangat baik dengan nilai Mean IoU sebesar 0,9240, Precision sebesar 0,9707, Recall sebesar 0,9495, dan F1 Score sebesar 0,9600, dengan tingkat prediksi benar mencapai 97,45% berdasarkan analisis confusion matrix berbasis piksel. Hasil tersebut menunjukkan bahwa arsitektur U-Net mampu melakukan segmentasi area defect biji kopi secara akurat dan konsisten, sehingga berpotensi digunakan sebagai dasar pengembangan sistem inspeksi kualitas kopi secara otomatis.

Kata kunci: Biji Kopi; Deteksi Cacat; U-Net; Deep Learning; Binary Segmentation

Abstract

Visual-manual identification of coffee bean defects is still prone to subjectivity and inconsistency in assessment, so a more accurate and efficient approach is needed. This study proposes a deep learning-based coffee bean image segmentation method using the U-Net architecture to detect the presence of defects in coffee beans in general using a binary segmentation approach. The dataset consists of 300 coffee bean images divided equally into 150 black coffee class images and 150 insect damage class images. The annotation process is carried out using a semi-automatic pseudo-labeling method based on Gaussian filtering, absolute difference, and thresholding to produce a ground truth mask in binary mask format. The training data is enriched through augmentation in the form of horizontal flip, vertical flip, rotation, and brightness and contrast adjustments. The model is trained using a combined loss function of Dice Loss and Binary Cross-Entropy with the Adam optimizer for 15 epochs and an early stopping mechanism. The evaluation results showed excellent performance with a Mean IoU value of 0.9240, Precision of 0.9707, Recall of 0.9495, and F1 Score of 0.9600, with a correct prediction rate reaching 97.45% based on pixel-based confusion matrix analysis. These results indicate that the U-Net architecture is capable of segmenting coffee bean defect areas accurately and consistently, so it has the potential to be used as a basis for developing an automatic coffee quality inspection system.

Keywords: Coffee Bean; Defect Detection; U-Net; Deep Learning; Binary Segmentation

1. PENDAHULUAN

Salah satu komoditas perkebunan di Indonesia yang berdampak signifikan bagi pertumbuhan perekonomian nasional adalah kopi [1]. Kopi menjadi produk unggulan dengan nilai ekonomi yang cukup besar di pasar lokal maupun internasional [2], serta berperan sebagai bahan baku utama dalam berbagai sektor industri [1].

Seiring dengan dinamika pasar yang terus berkembang, kualitas kopi saat ini menjadi faktor krusial dalam menjaga daya saing, terutama dalam menentukan nilai jual dan cita rasa produk [3]. Proses penentuan kualitas kopi umumnya dapat dilihat berdasarkan sistem nilai cacat dan tingkat kematangan yang mengacu pada kondisi fisik biji [4].

Pentingnya proses grading biji kopi dilakukan untuk memastikan standar kualitas yang mendukung mekanisme penetapan harga secara adil [5]. Salah satu aspek utama dalam proses tersebut yaitu mengidentifikasi cacat pada biji kopi, seperti *black bean* dan *insect damage*, yang secara langsung memengaruhi mutu dan nilai jual produk. Dalam praktiknya, proses identifikasi tersebut masih banyak mengandalkan penilaian secara visual-manual sehingga rentan pada subjektivitas penilaian dan rendahnya konsistensi hasil [6], serta cenderung membutuhkan waktu yang cukup lama karena menuntut proses analisis yang detail dan pengamatan yang mendalam [7]. Kondisi ini menjadi kendala terutama pada skala produksi besar yang menuntut efisiensi dan akurasi tinggi, sehingga berpengaruh terhadap penurunan kualitas produk serta efisiensi proses produksi kopi [8]. Oleh karena itu, diperlukan suatu pendekatan yang mampu mengidentifikasi dan memisahkan area cacat pada biji kopi secara akurat dan konsisten guna meningkatkan kualitas hasil grading.

Sejalan dengan perkembangan teknologi, pendekatan berbasis komputer vision menjadi solusi yang menjanjikan, di mana mesin dapat mengotomatisasi proses identifikasi citra [9]. Segmentasi citra menjadi tahap awal yang penting dalam proses tersebut karena berfungsi untuk memisahkan objek utama (biji kopi) sehingga citra dapat dianalisis lebih lanjut secara konsisten [10]. Metode segmentasi konvensional seperti thresholding dan klasifikasi berbasis fitur masih memiliki keterbatasan dalam menangani variasi kompleksitas citra, terutama pada variasi pencahayaan, tekstur, dan bentuk objek [11]. Pendekatan *deep learning*, khususnya menggunakan arsitektur U-Net, menawarkan kemampuan dalam menangkap fitur spasial secara detail melalui struktur *encoder-decoder* sehingga mampu menghasilkan segmentasi citra lebih optimal [12]. Metode ini dinilai efektif dalam mendeteksi objek dengan bentuk tidak beraturan serta ukuran kecil karena mampu menghasilkan detail batas yang lebih presisi [13], sehingga berpotensi meningkatkan akurasi identifikasi cacat pada biji kopi.

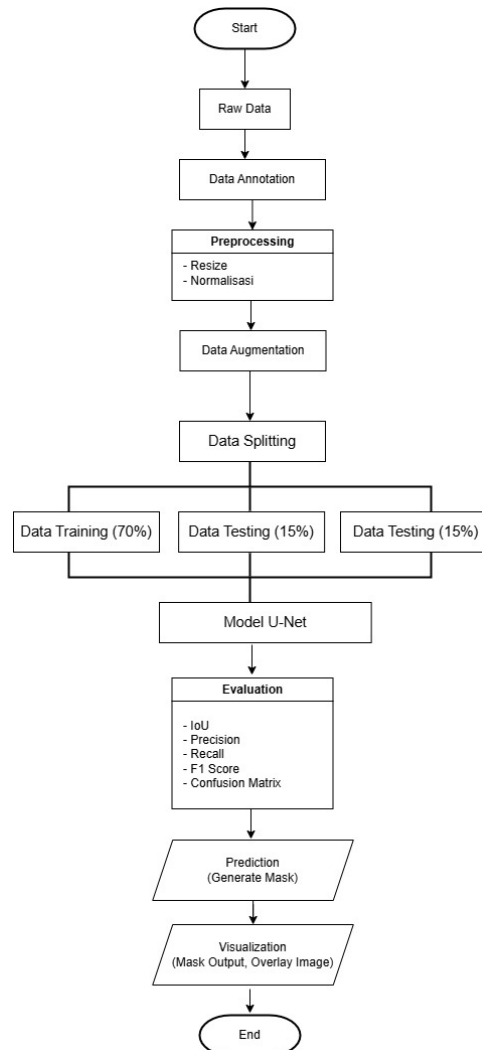
Penelitian mengenai penggunaan arsitektur U-Net dalam segmentasi citra telah banyak dilakukan dalam beberapa tahun terakhir, diantaranya penelitian dari [14] yang menerapkan arsitektur U-Net dikombinasikan dengan MobileNetV2 untuk meningkatkan efisiensi komputasi dalam proses segmentasi citra multi-kelas. Hasil penelitian ini menunjukkan bahwa penggunaan metode tersebut mampu mengatasi kompleksitas model tanpa mengorbankan akurasi segmentasi. Kemudian, penelitian oleh [15] yang mengusulkan penggunaan arsitektur U-Net pada citra daun kopi, dimana nilai *mean Intersection over Union* (IoU) yang

dihasilkan sebesar 0,89080 yang berarti menunjukkan bahwa model memiliki tingkat akurasi segmentasi yang sangat tinggi dalam membedakan area objek secara tepat. Selain itu, ada juga penelitian yang memanfaatkan arsitektur U-Net dalam mendeteksi kerusakan daun pakcoy [16]. Dari hasil penelitian ini diperoleh pemodelan yang mampu melakukan segmentasi area kerusakan dengan cukup baik yang dibuktikan dengan nilai akurasi global sebesar 96,8% dan *mean IoU* sebesar 0,683. Meskipun penelitian-penelitian tersebut memiliki perbedaan pada objek dan pendekatan yang digunakan, namun secara umum tetap relevan, sehingga dapat dijadikan landasan dalam pengembangan metode pada penelitian ini.

Berdasarkan keterbatasan pada pendekatan konvensional yang masih bergantung pada tahapan pra-pemrosesan yang cukup kompleks, seperti transformasi ruang warna (*grayscale* dan HSV), metode segmentasi tradisional, serta ekstraksi fitur tekstur seperti GLCM yang selanjutnya diklasifikasikan menggunakan algoritma machine learning. Penelitian ini bertujuan untuk menerapkan pendekatan *end-to-end* berbasis *deep learning* dengan arsitektur U-Net untuk segmentasi citra biji kopi. Pendekatan yang digunakan tidak lagi memerlukan rekayasa fitur secara manual, karena model secara langsung mempelajari representasi fitur dari citra untuk mengenali area objek sekaligus mengidentifikasi cacat pada kategori black bean dan insect damage secara lebih optimal. Selain itu, penelitian ini menggunakan data primer yang diperoleh dari kondisi nyata, sehingga mencerminkan variasi visual seperti perbedaan pencahayaan, *noise*, dan kompleksitas tekstur. Untuk meningkatkan ketahanan model, diterapkan pula tahapan pra-pemrosesan berupa reduksi noise dengan *Gaussian filtering*, penanganan variasi pencahayaan menggunakan *absolute difference*, serta augmentasi data, sehingga diharapkan model mampu menghasilkan segmentasi yang lebih stabil dan akurat pada kondisi citra dunia nyata.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan *deep learning* berbasis U-Net untuk memproses segmentasi citra biji kopi. Alur kerja penelitian dirancang guna memastikan data yang digunakan terstandarisasi dan siap dilatih oleh model.



Gambar 1. Alur Kerja Penelitian

Berdasarkan alur kerja penelitian yang ditampilkan pada Gambar 1. Proses penelitian ini dilakukan secara bertahap, mulai dari pengumpulan data hingga visualisasi hasil prediksi. Tahapan pertama dari penelitian ini yaitu mengumpulkan *raw data* berupa citra biji kopi dengan kategori cacat *black bean* dan *insect damage* yang digunakan sebagai objek penelitian. Data yang diperoleh belum sepenuhnya terstandarisasi sehingga diperlukan proses lanjutan agar dapat digunakan dalam pelatihan model.

Tahap selanjutnya adalah anotasi data, di mana dilakukan pelabelan secara *pixel-wise* pada citra biji kopi untuk membentuk *ground truth mask* yang merepresentasikan seluruh area biji kopi yang mengandung cacat sebagai *foreground* (label 1) dan latar belakang sebagai *background* (label 0) pada proses segmentasi. Kemudian, dilakukan tahap *preprocessing* meliputi *resize* seluruh citra menjadi 256×256 piksel agar sesuai dengan input model serta normalisasi nilai piksel untuk menstabilkan proses pelatihan. Berikutnya, data augmentasi melalui *horizontal flip*, *vertical flip*, rotasi, serta random *brightness* dan *contrast* guna menambah keragaman data dan meningkatkan kemampuan generalisasi model terhadap variasi orientasi objek maupun pencahayaan. Setelah proses tersebut,

dataset dibagi menjadi data *training*, *validation*, dan *testing* untuk keperluan pelatihan, evaluasi, dan pengujian model. Dataset dibagi menjadi 70% untuk data *training*, 15% untuk data *validation*, dan 15% untuk data *testing*. Data *training* digunakan untuk melatih model, sedangkan data *validation* digunakan untuk memantau performa model selama proses pelatihan dan menghindari *overfitting*. Sementara itu, data *testing* digunakan untuk menguji kemampuan generalisasi model terhadap data baru yang belum pernah dipelajari sebelumnya.

Proses utama dalam penelitian ini adalah penerapan model U-Net untuk melakukan segmentasi citra biji kopi guna mengidentifikasi area biji kopi yang mengalami cacat, mencakup dua kategori yaitu *black bean* dan *insect damage*, dengan pendekatan *binary segmentation* yang memperlakukan kedua kategori tersebut sebagai satu kelas *foreground*. Setelah proses pelatihan selesai, kinerja model dievaluasi menggunakan metrik *Intersection over Union (IoU)*, *Precision*, *Recall*, *F1-Score*, serta *Confusion Matrix* untuk mengukur kualitas hasil segmentasi secara kuantitatif berdasarkan kesesuaian antara prediksi model dan *ground truth mask* pada level piksel.


Model yang telah dilatih kemudian digunakan pada tahap *inference* untuk menghasilkan *mask* segmentasi pada citra baru. Hasil prediksi berupa mask biner yang merepresentasikan area biji kopi yang terdeteksi sebagai defect oleh model. Selanjutnya, pada tahap *visualization*, ditampilkan hasil segmentasi dalam bentuk *mask output* serta *overlay image*, yaitu penggabungan antara citra asli dan hasil prediksi, sehingga hasil segmentasi dapat diamati secara lebih jelas dan intuitif.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil dan analisis dari setiap tahapan penelitian, meliputi proses anotasi, *preprocessing*, augmentasi, pelatihan model U-Net, hingga evaluasi performa secara kuantitatif menggunakan metrik *IoU*, *Precision*, *Recall*, dan *F1-Score*, serta melalui visualisasi *overlay* dari hasil segmentasi.

3.1. Data Anotasi


Tahap anotasi data bertujuan untuk menghasilkan *ground truth mask* dalam format *binary mask*. Dataset yang digunakan terdiri dari 300 citra biji kopi, yang terbagi secara seimbang menjadi 150 citra kelas *black coffee* dan 150 citra kelas *insect damage*. *Mask* anotasi merepresentasikan seluruh area biji kopi yang teridentifikasi sebagai defect, di mana piksel biji diberi label 1 (*foreground*) dan piksel latar belakang diberi label 0 (*background*). Kedua kelas cacat tersebut diperlakukan sebagai satu kelas *foreground* dalam pendekatan *binary segmentation*, dengan tujuan mendeteksi keberadaan area cacat secara umum pada citra biji kopi tanpa membedakan jenis cacatnya. Citra diproses menggunakan *Gaussian filtering* guna meredam noise, dilanjutkan dengan perhitungan *absolute difference* untuk mempertajam kontras intensitas piksel pada area yang mengandung cacat. Hasil tersebut kemudian dikonversi menjadi citra biner melalui proses *thresholding*, yang selanjutnya difungsikan sebagai *mask* anotasi. Pendekatan ini diterapkan sebagai strategi *pseudo-labeling* dalam rangka mengefisienkan proses pembangunan dataset secara semi-otomatis. Hasil proses anotasi dapat dilihat pada Gambar 2, yang menampilkan citra asli dan binary mask sebagai *ground truth mask* segmentasi.



Gambar 2. Hasil Proses Anotasi Data

3.2. Data Prapemrosesan dan Data Augmentasi

Augmentasi data diterapkan secara eksklusif pada data latih untuk meningkatkan keberagaman distribusi data tanpa mengubah informasi semantik pada mask anotasi. Proses augmentasi dilakukan dengan transformasi yang meliputi *horizontal flip*, *vertical flip*, rotasi dengan batas sudut ± 30 derajat, serta penyesuaian *brightness* dan *contrast* secara acak, masing-masing diterapkan dengan probabilitas 0,5. Seluruh citra pada data latih maupun validasi diubah ukurannya menjadi 256×256 piksel untuk memenuhi dimensi input model U-Net. Sementara itu, data validasi hanya melalui proses *resize* tanpa augmentasi tambahan, guna memastikan evaluasi performa model dilakukan pada kondisi data yang representatif terhadap data asli. Hasil proses data *preprocessing* dan augmentasi dapat dilihat pada Gambar 3.



Gambar 3. Hasil Proses Data Prapemrosesan dan Augmentasi

3.3. Arsitektur Model U-Net

Model yang digunakan dalam penelitian ini adalah arsitektur U-Net yang diimplementasikan menggunakan *framework PyTorch*. Arsitektur ini terdiri dari dua blok konvolusi pada bagian encoder. Blok pertama memproses citra input berukuran 256×256 piksel dengan tiga kanal (RGB) menjadi *64 feature map*, sedangkan blok kedua mengekstraksi representasi fitur yang lebih abstrak menjadi *128 feature map*. Setiap blok konvolusi terdiri dari dua lapisan Conv2D dengan kernel berukuran 3×3 dan padding 1, yang diikuti oleh fungsi aktivasi ReLU.

Proses *downsampling* dilakukan menggunakan MaxPooling2D dengan ukuran kernel 2×2 untuk mengurangi dimensi spasial. Pada bagian *decoder*, proses *upsampling* dilakukan menggunakan Conv2DTranspose dengan ukuran kernel 2×2 dan *stride* 2 untuk memulihkan resolusi spasial. Mekanisme *skip connection* diterapkan dengan menggabungkan *feature map* dari *encoder* dan *decoder* pada tingkat resolusi yang sesuai, sehingga informasi spasial yang hilang selama proses *downsampling* dapat dipertahankan. Output akhir model berupa peta segmentasi satu kanal yang diaktivasi menggunakan fungsi *Sigmoid* untuk menghasilkan probabilitas setiap piksel terhadap kelas defect. Ringkasan arsitektur model disajikan pada Tabel 1.

Tabel 1. Ringkasan Arsitektur U-Net yang Diusulkan

Layers	Configuration
Input Layer	$256 \times 256 \times 3$
Conv2D	64 filters, 3×3 , padding 1, activation ReLU
Conv2D	64 filters, 3×3 , padding 1, activation ReLU
MaxPooling2D	Pool size 2×2
Conv2D	128 filters, 3×3 , padding 1, activation ReLU
Conv2D	128 filters, 3×3 , padding 1, activation ReLU
Conv2DTranspose	64 filters, 2×2 , stride 2 (upsampling)
Skip Connection	Concatenation of encoder and decoder feature maps
Conv2D	64 filters, 3×3 , padding 1, activation ReLU
Output Layer (Conv2D)	1 filter, 1×1 , activation Sigmoid

3.4. Konfigurasi Pelatihan

Proses pelatihan dilakukan menggunakan fungsi loss gabungan antara *Binary Cross-Entropy* (BCE) dan *Dice Loss*. BCE digunakan untuk melakukan optimasi klasifikasi piksel secara individual, sedangkan *Dice Loss* digunakan untuk mengatasi ketidakseimbangan antara area *defect* dan *non-defect* dengan memberikan penalti pada *overlap* yang rendah. Optimasi model dilakukan menggunakan Adam *optimizer* dengan *learning rate* sebesar 1×10^{-4} karena kemampuannya dalam melakukan adaptasi parameter secara efisien selama proses pelatihan. Untuk menghindari *overfitting*, diterapkan mekanisme *early stopping* dengan nilai *patience* sebesar 5 epoch, sehingga pelatihan dihentikan secara otomatis apabila *validation loss* tidak mengalami perbaikan signifikan dalam beberapa epoch berturut-turut. Proses pelatihan dilakukan selama maksimal 15 epoch dengan pemantauan nilai *training loss* dan *validation loss* pada setiap epoch.

3.5. Hasil Pelatihan dan Validasi

Selama proses pelatihan, model menunjukkan kemampuan konvergensi yang baik, di mana nilai *loss* mengalami penurunan secara signifikan pada epoch-epoch awal. Hal ini menunjukkan bahwa arsitektur U-Net yang diusulkan mampu mempelajari representasi fitur citra biji kopi secara efektif melalui mekanisme *encoder-decoder* dengan *skip connection*. Proses pelatihan dapat dibagi menjadi tiga fase yang berbeda. Pada fase pertama (epoch 1-3), kedua kurva mengalami penurunan yang cukup signifikan, di mana *training loss* turun dari 1,2332 menjadi 0,4000 dan *validation loss* turun drastis dari 1,0967 menjadi 0,1666,

merepresentasikan penurunan sebesar 84,8% hanya dalam tiga epoch. Penurunan yang signifikan ini mengindikasikan bahwa model berhasil mempelajari fitur-fitur dominan dari data secara efektif pada tahap awal pelatihan.

Pada fase kedua (epoch 4–7), kedua kurva mulai melandai dengan laju penurunan yang lebih gradual, menandakan model memasuki tahap refinement parameter yang lebih halus. Terdapat fluktuasi minor pada epoch ke-5 di mana validation loss sempat meningkat menjadi 0,1691, namun kondisi ini tidak berlanjut dan kembali menurun pada epoch berikutnya. Memasuki fase ketiga (epoch 8–15), model menunjukkan konvergensi yang stabil dengan training loss dan validation loss yang terus menurun secara konsisten hingga mencapai nilai akhir masing-masing sebesar 0,1866 dan 0,1217 pada epoch ke-15.


Mekanisme *early stopping* dengan *patience* 5 epoch tidak terpicu hingga akhir pelatihan, yang mengonfirmasi bahwa model masih mengalami peningkatan performa secara bertahap di setiap epoch. *Gap* antara *training loss* dan *validation loss* yang terjaga stabil di kisaran 0,06 sepanjang pelatihan mengindikasikan tidak adanya gejala *overfitting*, sekaligus menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Hasil lengkap pelatihan disajikan pada Tabel 2.

Tabel 2. *Loss* Pelatihan dan Validasi per Epoch

Epoch	Training Loss	Validation Loss
1	1.2332	1.0967
2	0.9121	0.5226
3	0.4000	0.1666
4	0.2469	0.1554
5	0.2362	0.1691
6	0.2387	0.1481
7	0.2221	0.1454
8	0.2092	0.1358
9	0.2111	0.1345
10	0.2050	0.1314
11	0.2053	0.1235
12	0.2025	0.1278
13	0.2024	0.1246
14	0.2005	0.1389
15	0.1866	0.1217

3.6. Kurva Galat Pelatihan dan Validasi

Grafik kurva training dan *validation loss* selama 15 epoch pelatihan ditunjukkan pada Gambar 4. Kedua kurva memperlihatkan penurunan yang cukup signifikan pada tahap awal pelatihan, di mana *training loss* menurun drastis dari 1,235 pada epoch pertama menjadi 0,250 pada epoch ke-4. Pola serupa juga terjadi pada *validation loss* yang turun dari 1,100 menjadi 0,148 pada periode yang sama. Penurunan yang cukup tajam ini mengindikasikan bahwa model mampu mempelajari representasi fitur dasar untuk proses segmentasi secara efektif pada awal pelatihan.



Gambar 4. Kurva Galat Pelatihan dan Validasi Model U-Net

Memasuki epoch ke-5 hingga ke-15, kedua kurva menunjukkan pola penurunan yang lebih landai dan stabil. Training loss kemudian berada pada kisaran 0,190–0,210, sedangkan validation loss mencapai nilai terendah sekitar 0,110 pada epoch terakhir. Pola konvergensi yang stabil tanpa adanya fluktuasi yang signifikan pada fase akhir pelatihan menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data validasi. Selain itu, tidak terlihat adanya indikasi *overfitting*, yang ditandai dengan menurunnya *validation loss* secara konsisten tanpa peningkatan yang berkelanjutan.

Selama proses pelatihan berlangsung, *validation loss* secara konsisten berada di bawah *training loss*. Hal ini dapat dipengaruhi oleh penerapan augmentasi data pada set pelatihan, yang menyebabkan distribusi data latih menjadi lebih kompleks dibandingkan data validasi. Mekanisme *early stopping* dengan parameter *patience* sebesar 5 epoch tidak aktif hingga epoch ke-15, yang menunjukkan bahwa model masih mengalami perbaikan performa hingga akhir proses pelatihan.

3.7. Evaluasi Kinerja Model

Tabel 3. Hasil Evaluasi Kinerja Model U-Net

Metrik	Nilai
<i>Mean IoU</i>	0,9240
<i>Precision</i>	0,9707
<i>Recall</i>	0,9495
<i>F1-Score</i>	0,9600

Evaluasi performa model U-Net dilakukan pada data uji menggunakan empat metrik utama, yaitu *Mean Intersection over Union (IoU)*, *Precision*, *Recall*, dan *F1-Score*. Hasil evaluasi secara lengkap disajikan pada Tabel 3. Model memperoleh nilai *Mean IoU* sebesar 0,9240 yang menunjukkan tingkat kesesuaian (*overlap*) antara hasil prediksi dan *ground truth mask* mencapai 92,40%. Nilai ini menunjukkan performa yang sangat baik dalam tugas segmentasi semantik, di mana model mampu melakukan deliniasi area defect dengan akurasi yang tinggi.

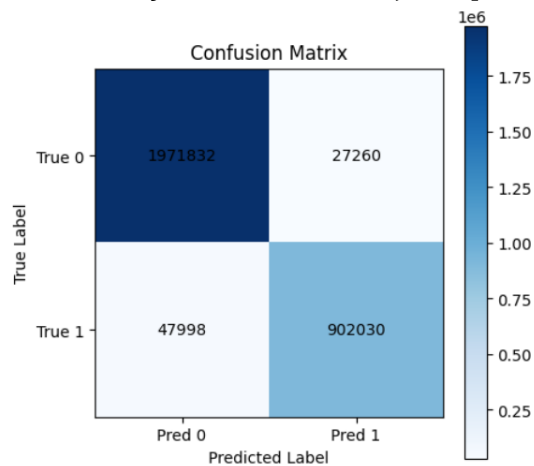
Nilai *Precision* yang diperoleh sebesar 0,9707 mengindikasikan bahwa 97,07% piksel yang diprediksi sebagai area defect merupakan prediksi yang benar, sehingga tingkat *false positive* yang dihasilkan relatif rendah. Sementara itu, nilai *Recall*

sebesar 0,9495 menunjukkan bahwa model mampu mendeteksi 94,95% dari seluruh area *defect* yang sebenarnya terdapat pada data uji. Selisih yang relatif kecil antara *Precision* dan *Recall* (sekitar 2,12%) mencerminkan adanya keseimbangan yang baik antara kemampuan model dalam menghindari kesalahan prediksi positif dan negatif.

Keseimbangan tersebut juga tercermin pada nilai *F1-Score* sebesar 0,9600, yang merepresentasikan rata-rata harmonik antara *Precision* dan *Recall*. Secara keseluruhan, hasil evaluasi kuantitatif ini menunjukkan bahwa model U-Net yang dikembangkan memiliki performa yang tinggi dalam tugas segmentasi citra biji kopi, dengan kemampuan deteksi yang akurat serta komprehensif terhadap berbagai karakteristik cacat yang terdapat pada dataset uji.

3.8. Confusion Matrix Berbasis Piksel

Evaluasi lanjutan terhadap kinerja model dilakukan melalui analisis *confusion matrix* berbasis piksel guna mengukur tingkat kesalahan klasifikasi antara area *defect* dan *background*. Hasil *confusion matrix* disajikan pada Gambar 5.

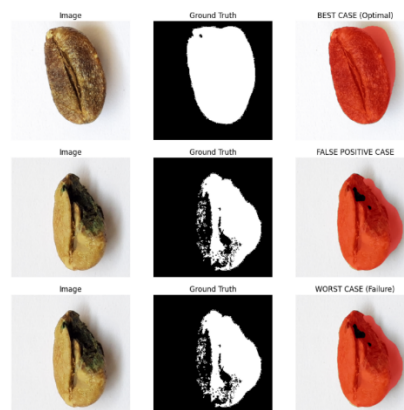


Gambar 5. *Confusion Matrix* Model U-Net

Berdasarkan gambar 5, dari total 2.949.120 piksel pada data uji, model berhasil mengklasifikasikan 1.971.832 piksel sebagai latar belakang citra (*background*) dengan benar (*True Negative*) dan 902.030 piksel sebagai area *defect* dengan benar (*True Positive*), sehingga tingkat prediksi benar mencapai 97,45% dari keseluruhan piksel. Sementara itu, terdapat 27.260 piksel *background* yang salah diklasifikasikan sebagai area *defect* (*False Positive*), atau sebesar 0,92%, serta 47.998 piksel area *defect* yang tidak berhasil terdeteksi oleh model (*False Negative*), yaitu sebesar 1,63%. Proporsi *False Negative* yang sedikit lebih tinggi dibandingkan *False Positive* menunjukkan bahwa model cenderung lebih konservatif dalam mendeteksi batas area biji kopi yang mengandung cacat, sehingga sebagian kecil piksel foreground masih berpotensi tidak teridentifikasi

Temuan ini juga sejalan dengan hasil evaluasi metrik sebelumnya, di mana *Precision* mencapai 97,07% dan *Recall* sebesar 94,95%. Secara keseluruhan, *confusion matrix* mengonfirmasi bahwa model U-Net memiliki kemampuan yang sangat baik dalam membedakan antara piksel area *defect* dan *background* pada citra biji kopi, dengan tingkat kesalahan klasifikasi yang relatif rendah.

3.9. Visualisasi Overlay



Gambar 6. Visualisasi Overlay

Visualisasi hasil segmentasi ditunjukkan pada Gambar 6. Evaluasi dilakukan melalui visualisasi overlay antara hasil prediksi model U-Net dan citra asli, yang dibagi ke dalam tiga kategori kasus, yaitu kasus optimal, *false positive*, dan kasus terburuk. Area berwarna merah pada *overlay* merepresentasikan piksel yang diprediksi oleh model sebagai *foreground*, yaitu area biji kopi yang terindikasi memiliki cacat.

Pada kasus optimal (baris pertama), model mampu melakukan segmentasi area biji kopi jenis *black coffee* dengan sangat baik, di mana hasil prediksi hampir sepenuhnya beririsan dengan *ground truth mask*. Karakteristik citra yang memiliki warna relatif homogen serta kontur objek yang jelas memungkinkan model membedakan *foreground* dan *background* dengan akurasi tinggi, sehingga kesalahan pada batas objek sangat minimal.

Pada kasus *false positive* (baris kedua), model dihadapkan pada biji kopi dengan jenis *insect damage* yang memiliki variasi tekstur dan warna yang lebih kompleks. Meskipun model berhasil mengidentifikasi area utama biji kopi dengan baik, terdapat beberapa area bertekstur granular di bagian dalam objek yang tidak terdeteksi sebagai *foreground*. Kondisi ini menyebabkan munculnya area yang tidak tersegmentasi pada hasil *overlay*, yang mengindikasikan adanya kesalahan pada area dengan pola kerusakan yang tidak homogen.

Sementara itu, pada kasus terburuk (baris ketiga), model mengalami kesulitan dalam melakukan segmentasi pada biji kopi dengan tingkat *insect damage* yang lebih parah. Kompleksitas pola kerusakan yang tinggi menyebabkan batas antara area *defect* dan latar belakang menjadi kurang jelas, sehingga sebagian area biji tidak terdeteksi secara optimal. Hal ini sejalan dengan nilai *Recall* sebesar 94,95% yang menunjukkan bahwa masih terdapat sejumlah kecil piksel *foreground* yang belum berhasil terklasifikasi, khususnya pada kasus dengan tingkat kerusakan yang kompleks.

KESIMPULAN

Penelitian ini telah berhasil mengembangkan model segmentasi cacat pada biji kopi menggunakan arsitektur U-Net dengan pendekatan *binary segmentation* pada dataset yang terdiri dari 300 citra, meliputi 150 citra kelas *black coffee* dan 150 citra kelas *insect damage*. Model dilatih selama 15 epoch menggunakan fungsi *loss*

gabungan *Dice Loss* dan *Binary Cross-Entropy* dengan *optimizer Adam*, dan menunjukkan konvergensi yang baik tanpa indikasi *overfitting* sepanjang proses pelatihan. Hasil evaluasi kuantitatif memperlihatkan performa yang sangat baik dengan nilai *Mean IoU* sebesar 0,9240, *Precision* sebesar 0,9707, *Recall* sebesar 0,9495, dan *F1 Score* sebesar 0,9600, yang dikonfirmasi oleh analisis *confusion matrix* dengan tingkat prediksi benar mencapai 97,45% dari total piksel data uji. Model terbukti bekerja optimal pada biji kopi dengan karakteristik visual yang homogen, meskipun masih menghadapi tantangan pada pola kerusakan yang kompleks dan tersebar khususnya pada kelas *insect damage*. Untuk penelitian selanjutnya, disarankan melakukan pengembangan ke arah *multi-class segmentation*, menambah jumlah data latih, serta mengeksplorasi arsitektur yang lebih dalam guna meningkatkan performa model.

DAFTAR PUSTAKA

- [1] S. M. Syadham and M. Akbar, "Klasifikasi Citra Biji Kopi Temanggung Menggunakan Gray Level Co-Occurrence Matrix – Convolutional Neural Network," *JITET (Jurnal Inform. dan Tek. Elektro Ter.*, vol. 13, no. 3, 2025.
- [2] W. R. Hasibuan, I. P. Sari, and M. Basri, "Klasifikasi Kerusakan (Cacat) pada Biji Kopi Arabika Menggunakan Algoritma KNN (K-Nearest Neighbor)," *Blend Sains J. Tek.*, vol. 3, no. 4, 2025.
- [3] H. Thai, H. Ko, and J. Huh, "Coffee Bean Defects Automatic Classification Realtime Application Adopting Deep Learning," *IEEE Access*, vol. 12, no. August, pp. 126503–126517, 2024.
- [4] I. G. P. A. Saputra, P. W. Rahayu, and I. M. D. Ardiada, "Analisis Tingkat Kematangan Sangraian Biji Kopi Menggunakan Ekstraksi Fitur Warna," *J-INTECH (Journal Inf. Technol.*, no. 204, pp. 123–128, 2024.
- [5] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, "Convolutional Neural Network dan Faster Region Convolutional Neural Network Untuk Klasifikasi Kualitas Biji Kopi Arabika," *JITET (Jurnal Inform. dan Tek. Elektro Ter.*, vol. 12, no. 3, pp. 2776–2785, 2024.
- [6] M. Farhan, A. Fauzi, and H. Khair, "Identifikasi Kualitas Biji Kopi Pada Pengolahan Citra Menggunakan Metode Backpropagation," *Kohesi J. Multidisiplin Saintek*, vol. 10, no. 5, pp. 1–12, 2025.
- [7] A. A. Hibatullah, A. Asriyanik, and W. Apriandari, "Klasifikasi Kualitas Jenis Kopi Halus Robusta Menggunakan Convolutional Neural Network (CNN) dan Mobilenet-V2," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 5, pp. 8650–8657, 2024.
- [8] A. Zandianto, M. Mahrijal, and I. Irwan, "Sistem Sortasi Biji Kopi Otomatis Menggunakan Sensor Warna TCS34725 dan Arduino Mega 2560," *J. Inov. Teknol. Terap.*, vol. 04, no. 1, 2026.
- [9] N. Krisdianto, R. K. Atharizqi, and W. T. Nurhasanaah, "Pengembangan Sistem Pengenalan Objek Multi-Kelas Berbasis Segmentasi Citra dengan YOLOv11 dan Streamlit," *IJINF (International J. Informatics)*, pp. 1–18, 2025.
- [10] S. A. Elvidamayantia and A. Ramadhanu, "Penerapan Algoritma K-Means Clustering dalam Segmentasi Citra Sayuran : Wortel, Kol, dan Terong Berbasis Matlab," *J. Sains Dan Teknol.*, vol. 5, no. 3, pp. 302–312, 2025.
- [11] A. Nurdiansyah and A. Ramadhanu, "Segmentasi Citra Buah Durian Dan

- Jagung Dengan Algoritma K-Nearest Neighbor Dan Principal Componen Analysis,” *J. Inform. Teknol. dan Sains*, vol. 7, no. 1, pp. 412–419, 2025.
- [12] F. A. Hermawati and V. A. Jaya, “Segmentasi Kepala Janin pada Citra Ultrasound Menggunakan Arsitektur Jaringan U-Net Fetal Head Segmentation in Ultrasound Images Using U-Net Network Architecture,” *Komputika J. Sist. Komput.*, vol. 13, no. 2, pp. 193–199, 2024.
- [13] A. Li, D. Li, and A. Wang, “A Two-Stage YOLOv5s–U-Net Framework for Defect Localization and Segmentation in Overhead Transmission Lines,” *Sensors (Basel)*, vol. 25, no. 9, 2025.
- [14] M. Adeva, “Arsitektur U-Net MobileNetV2 yang Efisien dan Akurat untuk Segmentasi Buah Multi-Kelas,” in *Seminar Nasional Informatika Bela Negara (SANTIKA)*, 2025, vol. 5, no. 2, pp. 180–183.
- [15] P. Kuppusamy, P. Pranavi, R. Jyothsna, B. S. Sahana, and L. Meghana, “A Synergistic Approach of Coffee Leaf Pathology Segmentation with Self-Attentive U-Net,” in *2025 IEEE International Conference on Emerging Technologies and Applications (MPSec ICETA)*, 2025, pp. 1–6.
- [16] N. K. Diani, M. W. A. Kesiman, I. M. G. S. Sunarya, and P. Z. E. S. Nugraha, “Perangkat Cerdas Berbasis U-Net untuk Memantau Kerusakan Daun Pakcoy Akibat Serangan Hama,” *J. Artif. Intell. Digit. Bus.*, vol. 5, no. 1, pp. 7097–7109, 2026.