



Analisis efisiensi arsitektur U-Net dengan encoder MobileNetV2 pada segmentasi karat daun kopi

Muhammad Adeva¹, Faisal Muttaqin^{*2}, Budi Mukhamad Mulyo³

Email: ¹22081010077@student.upnjatim.ac.id, ²faisalmuttaqin.if@upnjatim.ac.id, ³budi.m.mulyo.fasilkom@upnjatim.ac.id

^{1,2,3}Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

Diterima: 14 Maret 2026 | Direvisi: 23 April 2026 | Disetujui: 26 April 2026

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Penyakit Karat Daun Kopi (*Hemileia vastatrix*) merupakan ancaman serius bagi produktivitas perkebunan kopi Robusta. Identifikasi manual seringkali lambat dan subjektif, sementara metode segmentasi berbasis Deep Learning standar seperti U-Net dengan encoder VGG16 memiliki beban komputasi yang berat (~24,89 juta parameter), sehingga sulit diimplementasikan pada perangkat dengan sumber daya terbatas. Penelitian ini bertujuan untuk mengoptimalkan efisiensi komputasi dengan mengusulkan penggunaan arsitektur Lightweight U-Net berbasis encoder MobileNetV2. Kinerja model dievaluasi secara komparatif terhadap baseline VGG16 menggunakan dataset publik PlantSeg. Hasil eksperimen menunjukkan bahwa integrasi MobileNetV2 berhasil mereduksi ukuran model secara masif sebesar 96% (menjadi ~0,95 juta parameter) dan mempercepat waktu inferensi sebesar ~20% (76,28 ms). Meskipun terdapat sedikit penurunan akurasi F1-Score sebesar 0,3% dibandingkan baseline, arsitektur usulan menawarkan *trade-off* terbaik antara efisiensi dan akurasi, menjadikannya solusi yang layak untuk implementasi pada perangkat seluler petani.

Kata kunci: *Deep Learning; Efisiensi Komputasi; Karat Daun Kopi; MobileNetV2; U-Net*

Efficiency analysis of the U-Net architecture with a MobileNetV2 encoder for coffee leaf rust segmentation

Abstract

*Coffee Leaf Rust (*Hemileia vastatrix*) poses a serious threat to Robusta coffee productivity. Manual identification is often slow and subjective, while standard Deep Learning segmentation methods like U-Net with VGG16 encoder bear heavy computational loads (~24.89 million parameters), hindering deployment on resource-constrained devices. This study aims to optimize computational efficiency by proposing a Lightweight U-Net architecture based on the MobileNetV2 encoder. The model's performance was comparatively evaluated against the VGG16 baseline using the PlantSeg public dataset. Experimental results show that MobileNetV2 integration successfully reduced model size massively by 96% (to ~0.95 million parameters) and accelerated inference time by ~20% (76.28 ms). Although there was a slight F1-Score decrease of 0.3% compared to the baseline, the proposed architecture offers the best trade-off between efficiency and accuracy, making it a viable solution for mobile implementation*

Keywords: *Coffee Leaf Rust; Computational Efficiency; Deep Learning; MobileNetV2; U-Net.*

1. PENDAHULUAN

Industri kopi, khususnya varietas Robusta (*Coffea canephora*), memegang peranan vital dalam perekonomian agrikultur Indonesia. Namun, produktivitas sektor ini menghadapi ancaman persisten dari penyakit Karat Daun Kopi (KDK) yang disebabkan oleh jamur *Hemileia vastatrix*. Infeksi ini dapat menyebabkan defoliasi prematur dan penurunan kapasitas

fotosintesis yang berujung pada kerugian hasil panen yang signifikan [1]. Produksi kopi nasional pun mengalami fluktuasi akibat tantangan ini, padahal permintaan pasar terus meningkat [2]. Selama ini, metode pemantauan penyakit di tingkat petani masih sangat bergantung pada inspeksi visual manual. Metode konvensional ini memiliki kelemahan fundamental, yakni subjektivitas yang tinggi, proses yang lambat, dan rentan terhadap kesalahan manusia (human error) [3].

Dalam era Pertanian Presisi (Precision Agriculture), Deep Learning telah menjadi standar baru untuk deteksi penyakit tanaman, menggeser metode pengolahan citra tradisional [4]. Namun, tantangan utama saat ini bergeser dari sekadar klasifikasi akurasi tinggi menjadi implementasi praktis pada perangkat seluler di lapangan (in the wild) yang memiliki keterbatasan daya komputasi dan memori [5]. Untuk kasus penyakit tanaman, pendekatan segmentasi semantik dinilai lebih unggul dibandingkan klasifikasi citra biasa, karena mampu memetakan lokasi dan luas area infeksi secara presisi untuk perhitungan tingkat keparahan [6]. Arsitektur Convolutional Neural Network (CNN) tipe U-Net telah menjadi standar de facto dalam tugas segmentasi ini karena kemampuannya menangkap konteks lokal dan global melalui mekanisme skip connections [7].

Meskipun handal, U-Net standar umumnya menggunakan encoder (tulang punggung) yang berat seperti VGG16. Arsitektur ini memiliki jutaan parameter yang mengakibatkan borosnya sumber daya komputasi, sehingga sulit dijalankan secara real-time pada gawai petani. Untuk mengatasi hal ini, penggunaan arsitektur Lightweight seperti MobileNetV2 [8] sebagai encoder mulai diteliti. MobileNetV2 menggunakan Inverted Residuals dan Linear Bottlenecks untuk memangkas beban komputasi secara drastis. Efektivitas kombinasi U-Net dan MobileNetV2 telah terbukti berhasil pada domain medis, seperti pada segmentasi pembuluh darah retina [9] dan segmentasi polip [10], namun eksplorasinya pada domain penyakit tanaman kopi masih terbatas.

Selain itu, beberapa penelitian pada jurnal CoSciTech juga menunjukkan bahwa arsitektur deep learning ringan memiliki potensi besar untuk diterapkan pada permasalahan berbasis citra di bidang pertanian. Arianda dan Hadiwandura [16] mengembangkan model klasifikasi penyakit daun kelapa sawit berbasis MobileNetV2 dengan strategi transfer learning dan memperoleh akurasi 85%, sekaligus menekankan keunggulan arsitektur ringan untuk implementasi pada perangkat mobile. Di sisi lain, Handayani dkk. [17] menunjukkan bahwa arsitektur VGG-19 mampu memberikan performa tinggi untuk klasifikasi penyakit daun tomat dengan akurasi 97%, namun pendekatan berbasis backbone besar umumnya membutuhkan sumber daya komputasi yang lebih tinggi. Temuan tersebut memperkuat pentingnya penelitian ini, yaitu menganalisis trade-off antara efisiensi komputasi dan akurasi pada kasus yang lebih rinci, yakni segmentasi penyakit karat daun kopi.

Penelitian ini bertujuan untuk melakukan analisis komparatif efisiensi antara U-Net dengan encoder standar (VGG16) dan U-Net dengan encoder ringan (MobileNetV2). Fokus utama penelitian adalah memvalidasi kelayakan model ringan tersebut untuk implementasi pada perangkat seluler, dengan meninjau trade-off antara penurunan ukuran model dan kecepatan inferensi terhadap akurasi segmentasi yang dihasilkan.

2. METODE PENELITIAN

Bagian ini menguraikan tahapan dan pendekatan metodologis yang digunakan untuk membangun serta mengevaluasi model segmentasi penyakit karat daun kopi (*Coffee Leaf Rust*). Rangkaian penelitian ini dibagi menjadi tiga tahapan utama yang saling berkesinambungan. Penjelasan dimulai dari persiapan dan pra-pemrosesan dataset, dilanjutkan dengan perancangan arsitektur jaringan berbasis U-Net yang membandingkan dua jenis *encoder*, serta diakhiri dengan penetapan skenario pelatihan dan metrik evaluasi. Rincian pada setiap tahapan disajikan agar eksperimen ini dapat direproduksi dan diukur secara objektif.

2.1. Dataset dan Pra-pemrosesan

Penelitian ini menggunakan dataset publik PlantSeg [11] yang disaring khusus untuk kelas penyakit Karat Daun Kopi (*Coffee Leaf Rust*). Total dataset terdiri dari 128 citra RGB dan masker segmentasi ground truth. Dataset dibagi secara acak dengan rasio 70:15:15 menjadi data latih (89 citra), validasi (19 citra), dan uji (20 citra). Seluruh citra diubah ukurannya (resize) menjadi dimensi standar 256×256 piksel dan dinormalisasi ke rentang [0, 1]. Mengingat keterbatasan jumlah data latih, teknik augmentasi data *on-the-fly* diimplementasikan secara komprehensif menggunakan pustaka *Albumentations*. Transformasi ini dirancang khusus untuk mereplikasi variasi kondisi visual di lapangan, meliputi: *horizontal flip* dengan probabilitas eksekusi ($p=0.5$), rotasi spasial acak dalam rentang sudut -45° hingga $+45^\circ$ ($p=0.5$), serta penyesuaian fotometrik berupa *random brightness* dan *contrast* dengan limit faktor modifikasi sebesar 0.2 ($p=0.5$). Penambahan variasi pencahayaan ini sangat krusial karena citra daun kopi yang diakuisisi secara langsung di area perkebunan (*in the wild*) sangat rentan terhadap gangguan bayangan kanopi dan intensitas paparan cahaya matahari yang tidak homogen. Penerapan augmentasi multi-parameter ini secara efektif memperkaya variasi representasi data dan menekan laju *overfitting* secara masif selama fase pelatihan jaringan.

2.2. Arsitektur Jaringan

Studi ini membandingkan dua skenario arsitektur U-Net berdasarkan jenis *encoder* yang digunakan untuk menguji hipotesis efisiensi:

1. **Baseline (U-Net VGG16):** Menggunakan arsitektur VGG16 [13] dengan bobot *pre-trained* ImageNet sebagai *encoder*. Arsitektur ini merepresentasikan model segmentasi standar yang memiliki kapasitas ekstraksi fitur tinggi namun memiliki beban komputasi yang besar.
2. **Usulan (U-Net MobileNetV2):** Menggunakan MobileNetV2 *pre-trained* sebagai *encoder*. Kedua model menerapkan strategi *Transfer Learning* [14] untuk mempercepat konvergensi pelatihan dengan memanfaatkan bobot yang telah dilatih pada dataset skala besar. Modifikasi struktural dilakukan pada model usulan dengan menambahkan lapisan konvolusi kustom (*Custom Conv2D*) pada input awal untuk mempertahankan resolusi spasial 256×256 pada *skip connection* pertama. Lapisan konvolusi kustom ini diimplementasikan menggunakan filter berukuran 3×3 , parameter *stride* bernilai 1, dan *padding* bernilai 'same'. Tujuan utama dari lapisan transisi ini adalah untuk melakukan proyeksi ruang fitur (*feature space projection*). Melalui proyeksi ini, tensor *input* citra yang berdimensi $256 \times 256 \times 3$ dipetakan secara terstruktur menjadi $256 \times 256 \times 32$ sebelum akhirnya didistribusikan ke dalam jaringan blok *bottleneck* awal pada arsitektur MobileNetV2.

2.3. Skenario Pelatihan dan Evaluasi

Pelatihan model dilakukan pada lingkungan komputasi Google Colab menggunakan akselerator GPU NVIDIA Tesla T4. Fungsi kerugian (*Loss Function*) yang digunakan adalah *Hybrid Loss*, yaitu kombinasi *Categorical Cross-Entropy* (CCE) dan *Dice Loss* dengan bobot seimbang, yang bertujuan untuk mengatasi masalah ketidakseimbangan kelas (*class imbalance*) antara latar belakang dominan dan area lesi penyakit yang kecil. Pengoptimal *Adam* [15] digunakan dengan *learning rate* awal $1e-4$ yang diatur secara adaptif menggunakan *scheduler*. Kinerja model dievaluasi pada data uji (20 citra *unseen*) menggunakan metrik akurasi segmentasi *Intersection over Union* (IoU) dan *F1-Score*, serta metrik efisiensi komputasi yang mencakup jumlah parameter model (*model size*) dan rata-rata waktu inferensi (*inference time*) per citra. Pemilihan metrik evaluasi dalam penelitian ini didasarkan pada kebutuhan untuk menilai model dari dua sudut pandang sekaligus, yaitu kualitas segmentasi dan kelayakan implementasi praktis. Metrik IoU dan F1-Score digunakan karena keduanya mampu menggambarkan tingkat kesesuaian antara masker prediksi dan ground truth secara lebih representatif dibandingkan akurasi piksel biasa, terutama pada kasus segmentasi dengan distribusi kelas yang tidak seimbang [6]. Di sisi lain, jumlah parameter, ukuran model, dan waktu inferensi dipilih sebagai indikator efisiensi komputasi karena penelitian ini tidak hanya berorientasi pada performa prediksi, tetapi juga pada potensi penerapan model pada perangkat bergerak dengan memori dan daya komputasi terbatas [5]. Dengan kombinasi metrik tersebut, evaluasi yang dilakukan menjadi lebih komprehensif dalam menilai trade-off antara akurasi dan efisiensi.

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari serangkaian eksperimen yang telah dilakukan, beserta analisis komprehensif terhadap kinerja model. Pembahasan difokuskan pada perbandingan langsung antara model U-Net *baseline* (VGG16) dan model usulan yang lebih ringan (MobileNetV2). Evaluasi dijabarkan secara bertahap, meliputi analisis dinamika selama proses pelatihan, pengujian akurasi segmentasi secara kuantitatif, komparasi efisiensi komputasi, hingga validasi hasil prediksi secara kualitatif (*visual*). Analisis ini bertujuan untuk membuktikan hipotesis penelitian terkait efisiensi penggunaan sumber daya tanpa mengorbankan akurasi secara signifikan.

3.1. Dinamika Pelatihan

Proses pelatihan dipantau menggunakan fungsi loss pada data validasi. Hasil eksperimen menunjukkan bahwa model *baseline* (VGG16) mencapai konvergensi lebih cepat pada epoch ke-19, sedangkan model usulan (MobileNetV2) membutuhkan waktu lebih lama hingga epoch ke-56. Hal ini wajar mengingat MobileNetV2 adalah arsitektur ringan yang dilatih dari awal pada lapisan kustom, sehingga memerlukan lebih banyak iterasi untuk mematangkan fitur dibandingkan VGG16 yang memiliki kapasitas fitur sangat besar. Namun, kedua model menunjukkan stabilitas yang baik tanpa tanda-tanda *overfitting* yang signifikan berkat penerapan *augmentasi data*.

3.2. Evaluasi Akurasi Segmentasi

Kinerja segmentasi dievaluasi secara kuantitatif pada 20 citra data uji. Fokus evaluasi adalah pada kemampuan model mengidentifikasi kelas lesi penyakit. Ringkasan hasil metrik disajikan pada Tabel 1.

Tabel 1. Perbandingan Akurasi Segmentasi pada Data Uji

Model	Encoder	IoU (Lesi)	F1-Score	Precision	Recall
Baseline	VGG16	0.6618	0.7965	0.8755	0.7305
Usulan	MobileNetV2	0.6577	0.7935	0.8666	0.7317

Berdasarkan Tabel 1, model usulan (MobileNetV2) menghasilkan performa yang sangat kompetitif terhadap *baseline*. Selisih F1-Score antara kedua model sangat tipis, yaitu hanya 0,003 (0,3%). Menariknya, MobileNetV2 mencatat nilai *Recall* yang sedikit lebih tinggi (0.7317) dibandingkan VGG16 (0.7305), yang mengindikasikan bahwa arsitektur ringan ini cukup sensitif dalam mendeteksi area penyakit. Penurunan marjinal pada IoU ($\sim 0,004$) dapat dianggap sebagai *trade-off* yang dapat diterima mengingat efisiensi yang ditawarkan.

3.3. Analisis Efisiensi Komputasi

Kontribusi utama penelitian ini terletak pada efisiensi sumber daya. Perbandingan kompleksitas model dan kecepatan inferensi disajikan pada Tabel 2.

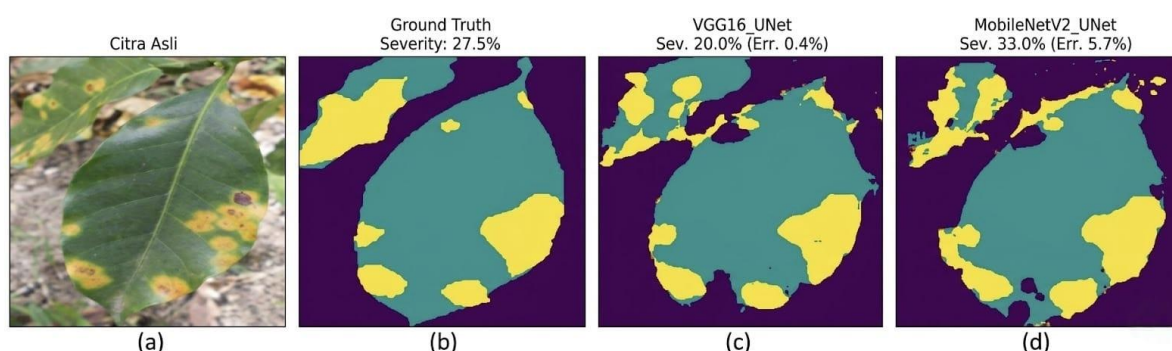
Tabel 2. Perbandingan Efisiensi Komputasi

Model	Encoder	Jumlah Parameter (Juta)	Ukuran Model (MB)	Waktu Inferensi (ms)	FPS
Baseline	VGG16	24,89	~95	95,76	~10
Usulan	MobileNetV2	0,96	~4	76,28	~13

Tabel 2 menunjukkan keunggulan masif arsitektur usulan. Penggunaan *encoder* MobileNetV2 berhasil memangkas jumlah parameter sebesar **96%** (dari ~24,89 juta menjadi hanya ~0,95 juta). Hal ini berdampak langsung pada ukuran *file* model yang menjadi sangat ringan, sehingga sangat ideal untuk distribusi aplikasi seluler. Dari sisi kecepatan, model usulan mampu memproses citra sekitar **20% lebih cepat** (76,28 ms per citra) dibandingkan *baseline*, memungkinkan pengalaman pengguna yang lebih responsif.

3.4 Analisis Kualitatif

Untuk memvalidasi hasil kuantitatif, dilakukan inspeksi visual terhadap masker prediksi yang dihasilkan model dibandingkan dengan *Ground Truth* (manual).



Gambar 1. Perbandingan Visual Hasil Segmentasi: (a) Citra Asli, (b) Ground Truth, (c) Prediksi Baseline VGG16, (d) Prediksi Usulan MobileNetV2.

Secara visual, model usulan mampu mendeteksi lokasi dan bentuk lesi dengan cukup akurat, menyerupai hasil baseline. Meskipun pada beberapa kasus kompleks terdapat sedikit noise di latar belakang, namun secara umum batas area penyakit teridentifikasi dengan baik. Hal ini mengonfirmasi bahwa *Lightweight U-Net* mampu mempertahankan representasi spasial yang memadai meskipun memiliki kapasitas parameter yang jauh lebih kecil. Lebih lanjut, Gambar 1 juga mendemonstrasikan evaluasi tingkat keparahan (*severity*), yang dihitung berdasarkan rasio persentase jumlah piksel terprediksi sebagai lesi karat daun terhadap total piksel luasan daun secara keseluruhan. Pada sampel visual tersebut, kalkulasi *Ground Truth* menunjukkan tingkat keparahan absolut sebesar 27.5%. Prediksi model *baseline* VGG16 menghasilkan estimasi *under-segmented* di angka 20.0%, sedangkan model usulan MobileNetV2 memberikan estimasi yang sedikit *over-segmented* di angka 33.0%. Kemunculan nilai *error* sebesar 5.7% pada model usulan mayoritas dikontribusikan oleh klasifikasi positif palsu (*False Positive*) pada area batas daun (*margin*) dan efek pantulan kilat cahaya (*specular reflection*) pada permukaan daun yang memiliki profil warna serupa dengan lesi. Meskipun demikian, selisih persentase ini masih tergolong wajar dan berada dalam ambang batas toleransi fungsional untuk estimasi kerusakan daun di level petani.

3.5 Perbandingan dengan Penelitian Terkait

Hasil penelitian ini menunjukkan bahwa penggunaan encoder MobileNetV2 pada arsitektur U-Net mampu menghasilkan performa segmentasi yang sangat kompetitif dibandingkan baseline VGG16, dengan selisih F1-Score yang sangat kecil namun disertai pengurangan jumlah parameter dan waktu inferensi yang signifikan. Temuan ini sejalan dengan penelitian Arianda dan Hadiwandura [16] yang memanfaatkan MobileNetV2 untuk klasifikasi penyakit daun kelapa sawit dan menekankan keunggulan efisiensi model ringan untuk penerapan pada perangkat bergerak. Kesamaan tersebut mengindikasikan bahwa karakteristik *lightweight* dari MobileNetV2 tidak hanya bermanfaat pada tugas klasifikasi, tetapi juga tetap relevan ketika diadaptasi ke tugas yang lebih kompleks seperti segmentasi semantik.

Di sisi lain, studi Handayani dkk. [17] memperlihatkan bahwa arsitektur VGG-19 dapat mencapai akurasi yang sangat tinggi pada klasifikasi penyakit daun tomat. Hal ini konsisten dengan hasil pada penelitian ini, di mana model berbasis encoder yang lebih besar masih mempertahankan keunggulan tipis dari sisi akurasi segmentasi. Namun, jika dikaitkan dengan kebutuhan implementasi di lapangan, khususnya pada perangkat dengan keterbatasan memori dan daya komputasi, maka model usulan berbasis MobileNetV2 memiliki nilai praktis yang lebih tinggi. Dengan demikian, penelitian ini menegaskan bahwa pemilihan arsitektur sebaiknya mempertimbangkan tujuan akhir penggunaan model, apakah berorientasi pada akurasi maksimum atau efisiensi implementasi.

Tabel 3. Perbandingan Penelitian Terkait

Peneliti	Tugas	Arsitektur	Dataset	Hasil Utama
Arianda dan Hadiwandura	Klasifikasi penyakit daun kelapa sawit	MobileNetV2	1200 citra, 4 kelas	Akurasi 85%
Handayani dkk.	Klasifikasi penyakit daun tomat	VGG-19	6600 citra	Akurasi 97%
Penelitian ini	Segmentasi karat daun kopi	U-Net + MobileNetV2 / VGG16	128 citra	F1-Score kompetitif dengan efisiensi lebih tinggi

Berdasarkan Tabel 3, dapat dilihat bahwa penelitian-penelitian terdahulu pada CoSciTech lebih banyak berfokus pada tugas klasifikasi citra penyakit tanaman, sedangkan penelitian ini berkontribusi pada tugas segmentasi semantik yang memberikan informasi lokasi dan luas area infeksi secara lebih detail. Perbedaan jenis tugas antara penelitian ini dan studi-studi terdahulu juga perlu dicermati dalam menafsirkan hasil. Penelitian Arianda dan Hadiwandura [16] serta Handayani dkk. [17] berfokus pada klasifikasi citra, yaitu menentukan label kelas dari keseluruhan gambar daun. Sebaliknya, penelitian ini menangani segmentasi semantik yang menuntut model untuk mengenali lokasi dan batas area lesi secara lebih detail pada tingkat piksel. Oleh karena itu, meskipun metrik yang digunakan tidak sepenuhnya dapat dibandingkan secara langsung, hasil penelitian ini tetap menunjukkan kontribusi penting karena berhasil mempertahankan performa yang kompetitif sambil menawarkan efisiensi yang lebih tinggi. Dengan kata lain, nilai tambah utama penelitian ini tidak hanya terletak pada akurasi, tetapi juga pada tingkat granularitas informasi yang dihasilkan untuk mendukung analisis tingkat keparahan penyakit.

3.6 Keterbatasan dan Arah Penelitian Lanjutan

Meskipun hasil penelitian menunjukkan bahwa arsitektur U-Net dengan encoder MobileNetV2 memiliki efisiensi yang jauh lebih baik dibandingkan baseline VGG16, penelitian ini masih memiliki beberapa keterbatasan. Pertama, jumlah data yang digunakan relatif terbatas, yaitu 128 citra, sehingga kemampuan generalisasi model pada variasi kondisi lapangan yang lebih luas masih perlu diuji lebih lanjut. Kedua, evaluasi dilakukan pada citra yang telah diubah ke ukuran 256×256 piksel, sehingga pengaruh resolusi input yang berbeda terhadap kualitas segmentasi belum dianalisis secara khusus. Ketiga, pengujian efisiensi komputasi masih dilakukan pada lingkungan eksperimen dan belum divalidasi secara langsung pada perangkat seluler nyata yang menjadi target implementasi.

Berdasarkan keterbatasan tersebut, penelitian lanjutan dapat diarahkan pada beberapa aspek. Pertama, perlu dilakukan pengujian menggunakan dataset yang lebih besar dan lebih beragam agar model lebih robust terhadap perubahan pencahayaan, sudut pengambilan gambar, serta kondisi daun yang kompleks. Kedua, model dapat dioptimalkan lebih lanjut melalui teknik kuantisasi atau konversi ke format TensorFlow Lite agar performanya pada perangkat mobile dapat dievaluasi secara langsung. Ketiga, eksplorasi encoder ringan lainnya seperti EfficientNet-Lite atau arsitektur segmentasi yang lebih baru dapat dilakukan untuk memperoleh kombinasi efisiensi dan akurasi yang lebih optimal.

3.7 Implikasi Praktis untuk Implementasi di Lapangan

Hasil penelitian ini memiliki implikasi praktis yang penting bagi pengembangan sistem deteksi penyakit tanaman berbasis perangkat bergerak. Dalam konteks pertanian presisi, petani membutuhkan model yang tidak hanya akurat, tetapi juga ringan, cepat, dan dapat dijalankan pada perangkat dengan sumber daya terbatas. Berdasarkan hasil pada Tabel 2, model U-Net dengan encoder MobileNetV2 menawarkan kombinasi yang lebih sesuai untuk kebutuhan tersebut karena memiliki jumlah parameter yang jauh lebih kecil, ukuran model yang lebih ringan, serta waktu inferensi yang lebih cepat dibandingkan baseline VGG16. Karakteristik ini membuat model usulan lebih realistis untuk diintegrasikan ke dalam aplikasi seluler yang digunakan petani secara langsung di lapangan.

Selain itu, kemampuan model usulan dalam mempertahankan performa segmentasi yang kompetitif menunjukkan bahwa efisiensi komputasi tidak selalu harus dibayar dengan penurunan akurasi yang besar. Hal ini penting karena pada skenario penggunaan nyata, kecepatan respons sistem dapat memengaruhi pengalaman pengguna dan tingkat adopsi teknologi oleh petani. Temuan ini sejalan dengan penelitian Arianda dan Hadiwandura [16] yang menekankan relevansi MobileNetV2 untuk aplikasi deteksi penyakit tanaman berbasis mobile. Dengan demikian, model yang dikembangkan dalam penelitian ini berpotensi menjadi dasar bagi sistem diagnosis awal karat daun kopi yang lebih mudah diakses, responsif, dan aplikatif untuk mendukung pengambilan keputusan di tingkat lapangan.

4. KESIMPULAN

Penelitian ini berhasil mendemonstrasikan efektivitas penggunaan arsitektur *Lightweight* U-Net dengan *encoder* MobileNetV2 untuk segmentasi penyakit Karat Daun Kopi. Berdasarkan hasil analisis komparatif terhadap *baseline* VGG16, dapat disimpulkan bahwa arsitektur usulan menawarkan keunggulan efisiensi yang signifikan. Penggunaan MobileNetV2 berhasil mereduksi jumlah parameter model sebesar 96% dan mempercepat waktu inferensi sebesar ~20%, tanpa mengorbankan akurasi secara drastis (selisih F1-Score hanya 0,3%).

Temuan ini mengonfirmasi bahwa modifikasi *encoder* menjadi arsitektur ringan adalah strategi yang efektif untuk mengatasi kendala komputasi pada penerapan *Deep Learning* di sektor pertanian. Model yang dihasilkan memiliki keseimbangan (*trade-*

off) yang optimal antara ukuran, kecepatan, dan ketepatan, menjadikannya solusi yang sangat layak untuk diimplementasikan pada perangkat seluler petani guna mendukung pemantauan kesehatan tanaman secara *real-time*. Penelitian selanjutnya disarankan untuk mengeksplorasi teknik kuantisasi model (*model quantization*) untuk meningkatkan efisiensi lebih lanjut pada format *TensorFlow Lite*.

DAFTAR PUSTAKA

- [1] International Coffee Organization (ICO), “Coffee Report and Outlook, December 2023,” 2023.
- [2] Badan Pusat Statistik (BPS), “Statistik Kopi Indonesia 2022,” 2023.
- [3] J. G. A. Barbedo, “Plant disease identification from individual lesions and spots using deep learning,” *Biosyst. Eng.*, vol. 180, pp. 96–107, 2019.
- [4] S. P. Mohanty, D. P. Hughes, and M. Salathé, “Using deep learning for image-based plant disease detection,” *Front. Plant Sci.*, vol. 7, p. 1419, 2016.
- [5] A. Picon *et al.*, “Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild,” *Comput. Electron. Agric.*, vol. 161, pp. 280–290, 2019.
- [6] S. Minaee, Y. Y. Boykov, F. Porikli, A. J. Plaza, N. Kehtarnavaz, and D. Terzopoulos, “Image segmentation using deep learning: A survey,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 44, no. 7, pp. 3523–3542, 2021.
- [7] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Springer, 2015, pp. 234–241.
- [8] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, “MobileNetV2: Inverted residuals and linear bottlenecks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 4510–4520.
- [9] T. Laibacher, T. Weyde, and S. Jalali, “M2U-Net: Effective and Efficient Retinal Vessel Segmentation for Real-World Applications,” in *CVPR Workshops*, 2019.
- [10] M. V. L. Branch and A. S. Carvalho, “Polyp Segmentation in Colonoscopy Images using U-Net-MobileNetV2,” 2021. [Online]. Available: <https://arxiv.org/abs/2103.15715>
- [11] T. Wei *et al.*, “PlantSeg: A Large-Scale In-the-wild Dataset for Plant Disease Segmentation,” 2024. [Online]. Available: <http://arxiv.org/abs/2409.04038>
- [12] C. Shorten and T. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, 2019.
- [13] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” 2015. [Online]. Available: <http://arxiv.org/abs/1409.1556>
- [14] S. J. Pan and Q. Yang, “A Survey on Transfer Learning,” *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345–1359, 2010.
- [15] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” 2017. [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [16] H. P. Arianda and T. Y. Hadiwandra, “Implementation of Deep Learning for Disease Classification in Oil Palm Leaves Using the MobileNetV2 Architecture,” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 3, pp. 453–462, 2025, doi: 10.37859/coscitech.v6i3.10306.
- [17] F. Handayani, B. Baidarus, S. Sunanto, B. A. Putra, C. Anggraini, and R. M. Taufiq, “Klasifikasi Citra Penyakit Daun Tomat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Arsitektur VGG-19,” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 3, pp. 405–413, 2025, doi: 10.37859/coscitech.v6i3.10699.