

## Pendekatan *computer vision* untuk analisis fitur visual dalam estimasi produktivitas tanaman kopi

<sup>1\*</sup>Jenie Sundari, <sup>2</sup>Ahmad Sinnun, <sup>3</sup>Fuad Nur Hasan, <sup>4</sup>Mulia Rahmayu

<sup>1,2</sup>Program Studi Rekayasa Perangkat Lunak, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, <sup>3</sup>Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, <sup>4</sup>Program Studi Teknologi Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

<sup>1,2,3</sup>Jalan Kramat Raya No.98, Jakarta Pusat, Indonesia

<sup>1</sup>jenie.jni@bsi.ac.id, <sup>2</sup>ahmad.axn@bsi.ac.id, <sup>3</sup>fuad.fnu@bsi.ac.id, <sup>4</sup>mulia.mlh@bsi.ac.id

### Abstract

Coffee productivity is an important factor in supporting the sustainability of smallholder plantations, particularly in the Sukabumi region. However, conventional estimation methods that rely on manual observation tend to be subjective and inefficient. Although previous studies have applied *computer vision* and *machine learning* for yield prediction, most approaches depend on large-scale datasets and expensive sensing technologies, and often do not integrate multiple visual plant features comprehensively. This indicates a research gap in the use of simple RGB-based imaging for productivity estimation. This study aims to analyze visual features of coffee plants and develop a coffee productivity estimation model using the Random Forest algorithm. The dataset consists of 10 coffee plant images collected directly from field observations, with extracted features including fruit count, fruit maturity percentage, canopy area, leaf color, and leaf texture. Model evaluation is performed using *Leave-One-Out Cross Validation* (LOOCV) method to optimize data utilization on a limited dataset. The results show that the model achieves a Mean Absolute Error (MAE) of 0.06, a Root Mean Square Error (RMSE) of 0.07, and a coefficient of determination ( $R^2$ ) of 0.91. These results indicate good predictive performance within the available dataset. Feature importance analysis reveals that fruit count and fruit maturity percentage are the most influential factors in determining coffee productivity. This study contributes to the development of a low-cost image-based estimation approach that is practical and potentially applicable for smart agriculture in smallholder coffee plantations, although the findings remain preliminary due to the limited dataset size.

**Keywords:** computer vision, coffee productivity, feature extraction, LOOCV, smart agriculture

### Abstrak

Produktivitas tanaman kopi merupakan faktor penting dalam mendukung keberlanjutan perkebunan rakyat, khususnya di wilayah Sukabumi. Namun, metode estimasi konvensional yang bergantung pada observasi manual cenderung subjektif dan kurang efisien. Meskipun berbagai penelitian sebelumnya telah memanfaatkan *computer vision* dan *machine learning* untuk estimasi hasil panen, sebagian besar pendekatan masih bergantung pada *dataset* berskala besar dan teknologi sensor yang mahal, serta sering kali belum mengintegrasikan berbagai fitur visual tanaman secara komprehensif. Hal ini menunjukkan adanya celah penelitian dalam pemanfaatan citra sederhana berbasis RGB untuk estimasi produktivitas. Penelitian ini bertujuan menganalisis fitur visual tanaman kopi dan mengembangkan model estimasi produktivitas kopi menggunakan algoritma *Random Forest*. *Dataset* yang digunakan terdiri dari 10 citra tanaman kopi yang diperoleh langsung dari observasi lapangan, dengan fitur yang diekstraksi meliputi jumlah buah, persentase kematangan buah, luas kanopi, warna daun, dan tekstur daun. Evaluasi model dilakukan menggunakan metode *Leave-One-Out Cross Validation* (LOOCV) untuk

mengoptimalkan pemanfaatan data pada *dataset* yang terbatas. Hasil penelitian menunjukkan nilai *Mean Absolute Error* (MAE) sebesar 0.06, *Root Mean Square Error* (RMSE) sebesar 0.07, dan koefisien determinasi ( $R^2$ ) mencapai 0.91. Hasil tersebut menunjukkan performa estimasi yang baik pada *dataset* yang digunakan. Analisis *feature importance* menunjukkan bahwa jumlah buah dan persentase kematangan buah merupakan faktor yang paling berpengaruh dalam menentukan produktivitas kopi. Penelitian ini berkontribusi pada pengembangan pendekatan estimasi berbasis citra berbiaya rendah yang praktis dan berpotensi diterapkan pada pertanian cerdas di perkebunan kopi rakyat, meskipun hasil penelitian ini masih bersifat *preliminary study* karena keterbatasan ukuran *dataset* yang digunakan.

**Kata Kunci:** *computer vision*, ekstraksi fitur, LOOCV, produktivitas kopi, pertanian cerdas

## 1. Pendahuluan

Produktivitas tanaman kopi merupakan faktor penting dalam mendukung keberlanjutan sektor perkebunan, khususnya pada skala perkebunan rakyat. Namun, estimasi produktivitas di lapangan masih banyak dilakukan secara manual melalui observasi visual, yang cenderung subjektif, memerlukan waktu lama, dan kurang konsisten [1]. Kondisi ini mendorong perlunya pendekatan yang lebih objektif dan efisien dalam pengelolaan tanaman. Seiring berkembangnya konsep *smart agriculture*, teknologi berbasis kecerdasan buatan semakin banyak dimanfaatkan untuk meningkatkan akurasi pengambilan keputusan di bidang pertanian [2], [3].

Salah satu teknologi yang berkembang pesat adalah *computer vision*, yang memungkinkan analisis kondisi tanaman melalui citra digital secara otomatis. Berbagai penelitian menunjukkan bahwa teknologi ini efektif digunakan untuk deteksi objek tanaman, identifikasi kesehatan tanaman, dan estimasi hasil panen [4], [5]. Dalam konteks estimasi produktivitas, metode *machine learning* seperti *Random Forest* dan *deep learning* telah menunjukkan performa yang baik dalam mengolah data visual maupun data lingkungan [6]–[7]. Pada komoditas kopi, pendekatan berbasis citra telah dimanfaatkan untuk mendeteksi buah, mengklasifikasikan tingkat kematangan, dan memperkirakan hasil panen [5], [8], [9].

Meskipun demikian, sebagian besar penelitian sebelumnya masih bergantung pada data berskala besar, seperti citra satelit, UAV, atau sensor multispektral, yang membutuhkan biaya tinggi dan infrastruktur khusus [10], [11]. Pendekatan tersebut kurang sesuai diterapkan pada perkebunan rakyat dengan keterbatasan sumber daya. Selain itu, penelitian terdahulu umumnya hanya berfokus pada satu jenis fitur visual, misalnya daun atau buah saja, sehingga belum merepresentasikan kondisi tanaman secara menyeluruh [12], [13]. Integrasi fitur generatif dan vegetatif diketahui berpotensi menghasilkan model estimasi yang lebih akurat.

Berdasarkan kondisi tersebut, terdapat dua celah penelitian utama. Pertama, masih terbatasnya pemanfaatan citra sederhana berbasis perangkat murah (*low-cost imaging*) untuk estimasi produktivitas kopi pada kondisi lapangan nyata. Kedua, belum optimalnya integrasi berbagai fitur visual tanaman dalam satu model estimasi yang komprehensif. Celah ini menunjukkan perlunya pendekatan yang lebih aplikatif, terjangkau, dan relevan bagi perkebunan kopi rakyat.

Penelitian ini bertujuan untuk menganalisis fitur visual tanaman kopi menggunakan pendekatan *computer vision* serta mengembangkan model estimasi produktivitas berbasis algoritma *Random Forest*. Pemilihan metode ini didasarkan pada celah penelitian yang menunjukkan bahwa sebagian besar studi sebelumnya menggunakan model kompleks yang membutuhkan *dataset* besar, sehingga kurang sesuai untuk data terbatas. Selain itu, penggunaan *Random Forest* pada estimasi produktivitas kopi berbasis fitur visual sederhana masih belum banyak dikaji, sehingga penelitian ini mengevaluasi potensinya sebagai model yang stabil dan sesuai untuk *dataset* kecil. Fitur yang dianalisis meliputi jumlah buah, tingkat kematangan buah, luas kanopi, warna daun, dan tekstur daun yang diekstraksi dari citra RGB

[14] hasil pengambilan langsung di perkebunan kopi Kabupaten Sukabumi. Mengingat keterbatasan jumlah *dataset*, evaluasi model dilakukan menggunakan metode *Leave-One-Out Cross Validation* (LOOCV) untuk mengoptimalkan pemanfaatan data [15].

Kontribusi utama penelitian ini terletak pada pengembangan model estimasi produktivitas kopi berbasis integrasi multi-fitur visual menggunakan citra sederhana dengan biaya rendah. Selain itu, penelitian ini menunjukkan penerapan metode *Random Forest* yang dikombinasikan dengan teknik evaluasi *Leave-One-Out Cross Validation* (LOOCV) untuk mengoptimalkan pemodelan pada dataset berukuran kecil. Pendekatan ini menawarkan solusi yang lebih praktis dan mudah diterapkan, khususnya bagi petani kopi skala kecil, sekaligus memberikan gambaran awal mengenai potensi pemanfaatan *computer vision* dalam pertanian cerdas.

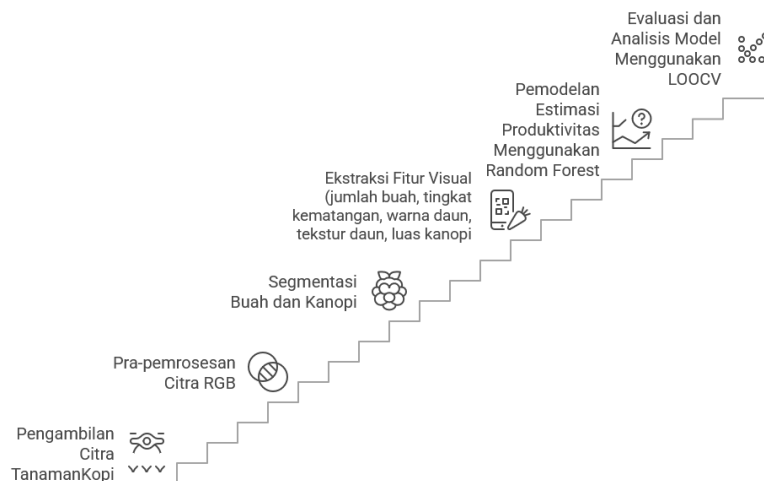
## 2. Metode Penelitian

### 2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan komputasional dengan desain eksperimen kuantitatif berbasis *computer vision* dan *machine learning*. Pendekatan ini dipilih karena penelitian berfokus pada pengolahan citra digital tanaman kopi untuk mengekstraksi fitur visual dan memodelkan estimasi produktivitas secara otomatis [16]. Desain eksperimental digunakan untuk mengevaluasi kemampuan model dalam mempelajari hubungan antara karakteristik visual tanaman dan nilai produktivitas aktual [17]. Selain itu, penelitian ini difokuskan pada penggunaan citra sederhana berbasis *low-cost imaging* pada estimasi produktivitas kopi, serta integrasi multi-fitur visual dalam satu model estimasi komprehensif.

### 2.2 Alur Penelitian

Alur penelitian pada Gambar 1 disusun secara sistematis dan berurutan untuk memastikan setiap tahapan berjalan terstruktur serta dapat direplikasi. Proses penelitian dimulai dari tahap pengumpulan data. *Dataset* dalam penelitian ini terdiri atas 10 citra digital tanaman kopi, di mana setiap citra mewakili satu individu tanaman. Jumlah *dataset* yang terbatas ini disebabkan oleh proses pengambilan data lapangan yang memerlukan pengamatan langsung serta pencatatan produktivitas aktual per pohon, sehingga membutuhkan waktu yang relatif lama dan tidak selalu mudah diperoleh dalam jumlah besar. Dalam konteks penelitian berbasis *computer vision* dengan data terbatas, penggunaan *dataset* terbatas masih umum digunakan pada tahap studi awal (*preliminary study*), selama didukung oleh metode evaluasi yang tepat seperti LOOCV yang mampu mengoptimalkan pemanfaatan seluruh data yang tersedia [18].



Gambar 1. Tahapan penelitian

Pengambilan citra dilakukan menggunakan kamera *smartphone* dengan resolusi minimal 12 MP, pada jarak  $\pm 1.5$  meter dari objek tanaman, dengan sudut pengambilan tegak lurus terhadap tanaman. Pengambilan dilakukan pada rentang waktu pukul 08.00–10.00 WIB untuk meminimalkan variasi pencahayaan ekstrem. Setiap citra disertai data produktivitas aktual (kg/pohon) yang diperoleh dari pencatatan hasil panen lapangan sebagai *ground truth*.

Tahap berikutnya adalah pra-pemrosesan citra, Pra-pemrosesan citra dilakukan untuk meningkatkan kualitas dan konsistensi data sebelum analisis lebih lanjut. Pada tahap ini, seluruh citra terlebih dahulu dinormalisasi ke ukuran tetap  $512 \times 512$  piksel untuk menyamakan dimensi *input* pada setiap sampel. Selanjutnya, citra RGB dikonversi ke ruang warna HSV karena representasi HSV lebih efektif dalam proses segmentasi berbasis warna dibanding RGB pada lingkungan alami [19]. Gangguan *noise* dikurangi dengan menggunakan median filter kernel  $3 \times 3$  yang dikenal efektif dalam menghilangkan *noise* impuls tanpa merusak tepi objek citra [20]. Setelah itu, koreksi pencahayaan dilakukan menggunakan histogram *equalization* untuk meningkatkan kontras citra dan menstabilkan distribusi intensitas cahaya [4]. Tahapan ini bertujuan menghasilkan kualitas citra yang seragam sehingga meningkatkan akurasi segmentasi dan ekstraksi fitur.

Setelah tahap pra-pemrosesan, dilakukan segmentasi objek untuk memisahkan area tanaman kopi dari latar belakang citra. Segmentasi dilakukan menggunakan metode *thresholding* berbasis ruang warna HSV (*Hue, Saturation, Value*) karena lebih stabil terhadap variasi pencahayaan dibandingkan RGB. Nilai *threshold* HSV ditentukan secara manual melalui pengamatan awal terhadap distribusi warna pada beberapa sampel citra tanaman kopi, khususnya pada area daun, buah, dan kanopi. Rentang nilai HSV kemudian disesuaikan secara empiris hingga mampu memisahkan objek tanaman dan latar belakang secara optimal. Hasil segmentasi divalidasi secara visual dengan membandingkan citra asli dan *mask* segmentasi untuk memastikan area tanaman berhasil terdeteksi dengan baik tanpa kehilangan objek utama. Hasil segmentasi ini selanjutnya digunakan sebagai dasar dalam proses ekstraksi fitur visual tanaman kopi.

Tahap selanjutnya adalah ekstraksi fitur visual. Ekstraksi fitur visual dilakukan untuk memperoleh karakteristik utama tanaman kopi yang berkaitan dengan produktivitas. Fitur visual yang digunakan dalam penelitian ini meliputi jumlah buah, tingkat kematangan buah, luas kanopi, warna daun, dan tekstur daun yang diekstraksi dari citra hasil segmentasi tanaman kopi. Jumlah buah diperoleh menggunakan metode *contour detection*, yaitu dengan mendeteksi area objek buah berdasarkan perbedaan warna terhadap latar belakang setelah proses segmentasi HSV. Setiap objek buah yang terdeteksi dihitung sebagai satu unit dengan memanfaatkan fungsi pencarian kontur dan penyaringan ukuran objek untuk menghindari *noise*. Tingkat kematangan buah ditentukan melalui klasifikasi warna pada ruang HSV (*Hue, Saturation, Value*). Rentang nilai *hue* digunakan untuk membedakan tingkat kematangan buah kopi, yaitu hijau (35–85) untuk buah mentah, kuning/oranye (15–34) untuk buah setengah matang, dan merah (0–14 serta 160–180) untuk buah matang. Proses klasifikasi dilakukan menggunakan teknik *color thresholding* pada area buah yang telah terdeteksi sebelumnya. Pemilihan rentang HSV tersebut mengacu pada karakteristik umum perubahan warna buah kopi selama proses pematangan dan didukung oleh penelitian sebelumnya yang menggunakan pendekatan HSV untuk klasifikasi kematangan buah berbasis citra digital karena lebih stabil terhadap variasi pencahayaan dibandingkan ruang warna RGB.

Luas kanopi dihitung dari hasil segmentasi area tanaman menggunakan *threshold* warna hijau pada ruang HSV, sehingga diperoleh *mask* biner yang merepresentasikan area daun dan cabang. Jumlah piksel pada area tersebut kemudian dikonversi menjadi satuan  $\text{cm}^2$  menggunakan faktor skala yang diperoleh dari pengukuran jarak pengambilan citra dan referensi ukuran objek di lapangan. Warna daun ditentukan berdasarkan rata-rata intensitas

kanal hijau (*G channel*) dari citra RGB pada area hasil segmentasi daun, yang mencerminkan kondisi fisiologis tanaman.

Sementara itu, tekstur daun diekstraksi menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) yaitu metode statistik tekstur yang menganalisis hubungan spasial antar piksel dalam citra dan telah banyak digunakan dalam analisis citra pertanian [21]. Penelitian ini menggunakan parameter jarak (*distance*) sebesar 1 piksel dan sudut (*angle*) 0°. Berdasarkan matriks ko-okurensi yang dihasilkan, dihitung empat fitur tekstur utama, yaitu *contrast*, *correlation*, *energy*, dan *homogeneity*. Parameter *contrast* digunakan untuk mengukur variasi intensitas piksel, *correlation* untuk mengevaluasi hubungan linear antar piksel, *energy* untuk merepresentasikan tingkat keseragaman pola tekstur, dan *homogeneity* untuk mengukur kedekatan distribusi piksel terhadap diagonal matriks GLCM. Kombinasi keempat fitur tersebut digunakan untuk memberikan representasi tekstur daun yang lebih komprehensif dalam proses estimasi produktivitas tanaman kopi.

Seluruh proses ekstraksi fitur dilakukan secara semi otomatis untuk menghasilkan *dataset* numerik yang digunakan dalam pemodelan estimasi produktivitas. Proses ekstraksi dilakukan secara otomatis melalui algoritma pengolahan citra, namun masih melibatkan penyesuaian *threshold* HSV secara manual pada tahap awal segmentasi serta validasi visual untuk memastikan objek tanaman terdeteksi dengan baik. Pendekatan ini dipilih untuk menjaga akurasi segmentasi pada kondisi pencahayaan lapangan yang bervariasi.

Fitur-fitur yang diperoleh kemudian digunakan pada tahap pemodelan *machine learning*. Penelitian ini menggunakan algoritma *Random Forest* sebagai model estimasi utama. *Random Forest* merupakan metode *ensemble learning* yang membangun banyak pohon keputusan (*decision trees*) dan menggabungkan hasil estimasi untuk meningkatkan akurasi serta stabilitas model [22]. Algoritma ini diperkenalkan oleh Breiman dan dikenal efektif dalam menangani data non-linear, berdimensi banyak, serta tahan terhadap *overfitting* [23]. Pada penelitian ini, parameter model yang digunakan meliputi jumlah *decision tree* sebanyak 100, *max depth* tanpa batas, dan *random state* sebesar 42. *Random Forest* dipilih karena stabil pada *dataset* kecil, *robust* terhadap variasi data, dan sesuai untuk estimasi berbasis multi-fitur visual [24].

Tahap terakhir adalah evaluasi hasil yang dilakukan untuk mengukur performa model estimasi secara kuantitatif. Evaluasi model menggunakan metode LOOCV, yaitu teknik validasi di mana pada setiap iterasi satu sampel digunakan sebagai data uji dan sisanya digunakan sebagai data latih, hingga seluruh sampel memperoleh giliran sebagai data uji. *Dataset* terdiri dari 10 sampel, maka proses LOOCV dilakukan sebanyak 10 iterasi. Pada setiap iterasi dihitung nilai galat estimasi, kemudian seluruh hasil digabungkan untuk memperoleh nilai evaluasi akhir berupa rata-rata dari seluruh iterasi LOOCV.

Kinerja model diukur menggunakan tiga metrik evaluasi, yaitu MAE, RMSE, dan R<sup>2</sup>. MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan estimasi, yang dihitung dengan Persamaan (1).

$$MAE = \frac{1}{n} \sum_i^n |y_i - \hat{y}_i| \quad (1)$$

di mana  $y_1$  adalah nilai aktual  $\hat{y}_i$  adalah nilai estimasi, dan  $n$  adalah jumlah sampel. RMSE digunakan untuk mengukur akar rata-rata kuadrat eror estimasi, sebagaimana ditunjukkan pada Persamaan (2).

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

Sementara itu, koefisien determinasi (R<sup>2</sup>) digunakan untuk menilai seberapa baik model menjelaskan variasi data aktual, yang dihitung menggunakan Persamaan (3).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

dengan  $\hat{y}$  menyatakan rata-rata nilai aktual. Nilai MAE, RMSE, dan  $R^2$  pada penelitian ini merupakan nilai rata-rata agregat dari seluruh iterasi LOOCV, sehingga mencerminkan performa model secara keseluruhan dan lebih representatif terhadap *dataset* berukuran kecil.

### 3. Hasil dan Pembahasan

#### 3.1 Hasil Analisis Fitur Visual Tanaman Kopi

Berdasarkan hasil ekstraksi fitur, diperoleh lima fitur visual utama yang digunakan dalam pemodelan estimasi produktivitas, yaitu jumlah buah, tingkat kematangan buah, luas kanopi, warna daun, dan tekstur daun. *Dataset* penelitian terdiri dari 10 sampel tanaman kopi, di mana setiap sampel direpresentasikan dalam bentuk nilai numerik hasil ekstraksi fitur dari citra RGB.

Hasil analisis menunjukkan bahwa jumlah buah dan tingkat kematangan buah memiliki variasi paling signifikan antar sampel, serta memperlihatkan hubungan langsung dengan produktivitas aktual tanaman. Tanaman dengan proporsi buah matang lebih tinggi cenderung menghasilkan nilai produktivitas yang lebih besar. Sementara itu, warna daun hijau pekat dan tekstur daun homogen umumnya ditemukan pada tanaman dengan kondisi fisiologis yang lebih baik. Hal ini menunjukkan bahwa kombinasi fitur generatif dan vegetatif berpotensi memberikan representasi kondisi tanaman yang lebih komprehensif dalam proses estimasi produktivitas kopi.

Hasil analisis tersebut sejalan dengan penelitian Abreu Júnior et al. [8], yang menunjukkan bahwa fitur visual berbasis citra multispektral memiliki korelasi kuat terhadap estimasi hasil panen kopi. Pendekatan citra RGB yang digunakan dalam penelitian ini memiliki keunggulan dari sisi biaya dan kemudahan implementasi dibandingkan metode multispektral. Citra RGB dapat diperoleh menggunakan kamera *smartphone* tanpa memerlukan sensor khusus atau proses kalibrasi yang kompleks, sehingga lebih mudah diimplementasikan dan aplikatif bagi petani skala kecil [1]. Sebaliknya, citra multispektral mampu menangkap informasi spektral yang lebih kaya, seperti *near-infrared*, sehingga umumnya menghasilkan akurasi yang lebih tinggi dalam analisis kondisi tanaman. Dengan demikian, terdapat *trade-off* antara kedua pendekatan tersebut. Metode multispektral unggul dalam akurasi namun memiliki biaya dan kompleksitas tinggi, sedangkan pendekatan RGB menawarkan solusi yang lebih sederhana, ekonomis, dan lebih mudah diterapkan pada perkebunan kopi skala kecil.

#### 3.2 Visualisasi Hasil Ekstraksi Fitur

Visualisasi hasil ekstraksi fitur ditunjukkan pada Gambar 2, yang memperlihatkan tahapan identifikasi objek buah berdasarkan tingkat kematangan. Sistem mendeteksi buah kopi matang, setengah matang, dan mentah menggunakan klasifikasi warna berbasis segmentasi HSV. Pada visualisasi tersebut:

1. *bounding box* merah menunjukkan buah matang,
2. *bounding box* kuning menunjukkan buah setengah matang,
3. *bounding box* hijau menunjukkan buah mentah.

Pendekatan ini memungkinkan identifikasi visual yang sederhana namun efektif untuk memperoleh informasi kuantitatif terkait distribusi kematangan buah pada tiap tanaman.



**Gambar 2.** Visualisasi hasil ekstraksi fitur visual tanaman kopi

Gambar 2 menunjukkan proses identifikasi fitur visual tanaman kopi. Citra asli digunakan sebagai *input*, kemudian dilakukan deteksi buah berdasarkan tingkat kematangan menggunakan penandaan warna. Fitur visual hasil ekstraksi fitur tersebut selanjutnya digunakan sebagai variabel *input* dalam proses estimasi produktivitas tanaman dalam satuan kilogram.

### 3.3 Hasil Pemodelan Estimasi Produktivitas

Evaluasi kinerja model estimasi dilakukan untuk mengukur tingkat akurasi dan kemampuan generalisasi model *Random Forest* dalam mengestimasi produktivitas tanaman kopi. Perbandingan antara nilai produktivitas aktual dan hasil estimasi model disajikan pada Tabel 1.

**Tabel 1.** Perbandingan nilai aktual dan estimasi produktivitas

No.	Produktivitas Aktual (kg)	Estimasi RF (kg)	Error Absolut
1	1.85	1.78	0.07
2	1.60	1.55	0.05
3	1.20	1.28	0.08
4	0.85	0.90	0.05
5	0.65	0.70	0.05
6	1.75	1.70	0.05
7	1.50	1.45	0.05
8	1.35	1.30	0.05
9	1.00	1.05	0.05
10	0.50	0.60	0.10

Secara umum, hasil estimasi pada Tabel 1 menunjukkan bahwa nilai estimasi model memiliki deviasi yang relatif kecil terhadap nilai produktivitas aktual pada sebagian besar sampel. Selisih estimasi pada mayoritas data berada pada rentang 0.05–0.08 kg, meskipun terdapat satu sampel dengan error absolut sebesar 0.10 kg. Hasil evaluasi model menggunakan metrik MAE, RMSE, dan  $R^2$  disajikan pada Tabel 2.

**Tabel 2.** Evaluasi kinerja model *Random Forest*

<b>Metrik Evaluasi Nilai</b>	
MAE	0.06
RMSE	0.07
R <sup>2</sup>	0.91

Nilai MAE sebesar 0.06 dan RMSE sebesar 0.07 menunjukkan bahwa rata-rata kesalahan estimasi berada pada tingkat yang relatif rendah. Jika diinterpretasikan dalam konteks rentang produktivitas pada *dataset*, yaitu sekitar 0.50 hingga 1.85 kg per pohon, maka kesalahan estimasi rata-rata berada pada kisaran  $\pm 3\text{--}5\%$  dari nilai produktivitas aktual. Hal ini menunjukkan bahwa deviasi model relatif kecil dibandingkan variasi data yang ada. Secara praktis, selisih sekitar 0.06–0.07 kg per pohon masih dapat diterima untuk kebutuhan estimasi awal di tingkat perkebunan rakyat, terutama dalam pengambilan keputusan sederhana seperti pemantauan hasil atau perencanaan panen. Nilai R<sup>2</sup> sebesar 0.91 juga mengindikasikan bahwa model mampu menjelaskan 91% variasi produktivitas pada *dataset* yang digunakan. Meskipun demikian, hasil ini tetap perlu ditafsirkan secara hati-hati mengingat ukuran *dataset* yang terbatas, sehingga performa model belum tentu merepresentasikan kondisi yang lebih luas. Pada Tabel 3, analisis *feature importance* menunjukkan bahwa jumlah buah dan persentase buah matang merupakan dua variabel paling dominan dalam estimasi produktivitas.

**Tabel 3.** *Feature importance (Random Forest)*

<b>Fitur</b>	<b>Nilai Kepentingan</b>
Jumlah Buah	0.35
% Buah Matang	0.30
Luas Kanopi	0.20
Tekstur (GLCM)	0.10
Warna Daun ( <i>Channel G</i> )	0.05

Dominasi kedua fitur tersebut mengindikasikan bahwa indikator generatif memiliki kontribusi lebih besar dibanding indikator vegetatif dalam memperkirakan hasil panen kopi. Temuan ini konsisten dengan penelitian Eron et al. [14], yang melaporkan bahwa karakteristik buah merupakan prediktor utama pada sistem monitoring kopi berbasis *computer vision*.

Hasil penelitian menunjukkan bahwa pendekatan berbasis citra RGB sederhana dapat digunakan untuk mengestimasi produktivitas kopi dengan performa yang menjanjikan, meskipun tidak menggunakan sensor mahal seperti UAV atau multispektral [10], [25]. Hal ini memperkuat potensi penerapan teknologi *low-cost imaging* untuk petani kopi skala kecil.

Jika dibandingkan penelitian sebelumnya yang menggunakan *dataset* besar dan sensor kompleks [8], [23], penelitian ini memiliki keunggulan pada aspek keterjangkauan implementasi. Namun demikian, keterbatasan utama penelitian ini terletak pada ukuran *dataset* yang masih terbatas (10 sampel), sehingga generalisasi model ke populasi yang lebih luas belum dapat dipastikan.

Selain itu, penggunaan LOOCV memang sesuai untuk *dataset* kecil, tetapi belum sepenuhnya menggantikan kebutuhan validasi eksternal pada *dataset* independen. Oleh karena itu, hasil penelitian ini lebih tepat diposisikan sebagai penelitian awal yang menunjukkan potensi metode, bukan sebagai model final yang siap diimplementasikan secara luas.

#### 4. Kesimpulan

Penelitian ini bertujuan untuk menganalisis fitur visual tanaman kopi dan mengevaluasi penggunaan algoritma *Random Forest* dalam estimasi produktivitas berbasis citra RGB sederhana. Hasil menunjukkan bahwa model mampu menangkap hubungan antara fitur visual dan produktivitas dengan nilai MAE sebesar 0.06, RMSE sebesar 0.07, dan  $R^2$  sebesar 0.91 pada *dataset* yang digunakan. Analisis *feature importance* mengindikasikan bahwa jumlah buah dan persentase kematangan buah merupakan faktor dominan, sementara fitur lainnya berperan sebagai pendukung dalam meningkatkan akurasi estimasi.

Penelitian ini menunjukkan bahwa pendekatan berbasis *computer vision* dan *low-cost imaging* berpotensi menjadi alternatif yang lebih sederhana dan terjangkau untuk mendukung estimasi produktivitas kopi pada skala perkebunan rakyat. Meskipun demikian, hasil ini perlu ditafsirkan secara hati-hati karena jumlah *dataset* terbatas dan hanya mencakup satu lokasi, sehingga belum mencerminkan kemampuan generalisasi model secara luas. Oleh karena itu, penelitian ini diposisikan sebagai studi pendahuluan, dan diperlukan pengujian lebih lanjut dengan *dataset* yang lebih besar dan beragam untuk memvalidasi keandalan pendekatan yang diusulkan.

#### Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Universitas Bina Sarana Informatika atas dukungan dan kerja sama yang diberikan dalam pelaksanaan penelitian ini, serta kepada seluruh pihak yang telah berkontribusi dalam penyediaan data dan informasi yang dibutuhkan.

#### Pernyataan

**Kontribusi Penulis.** J.S.: konseptualisasi penelitian, perancangan metode, pengumpulan data lapangan, implementasi program, analisis data, dan penulisan draf awal naskah. A.S.: validasi eksperimen, evaluasi hasil pemodelan, analisis statistik. F.N.H.: supervisi penelitian, pengawasan keseluruhan proyek, evaluasi metodologi, dan persetujuan akhir naskah sebelum publikasi. M.R.: peninjauan dan penyuntingan naskah.

**Pendanaan.** Penelitian ini tidak menerima pendanaan khusus dari lembaga pemerintah, komersial, maupun organisasi nirlaba.

**Konflik Kepentingan.** Penulis menyatakan tidak terdapat konflik kepentingan terkait publikasi artikel ini.

**Ketersediaan Data.** Data tersedia dari penulis korespondensi atas permintaan yang wajar.

**Penggunaan Kecerdasan Buatan (AI).** Penulis menyatakan bahwa penggunaan alat berbasis kecerdasan buatan (AI) hanya terbatas pada aspek penyuntingan bahasa dan tidak mempengaruhi substansi ilmiah penelitian.

#### Daftar Referensi

- [1] A. N. Angelopoulos, J. C. Duchi, and T. Zrnic, "PPI++: Efficient prediction-powered inference," *arXiv Prepr. arXiv:2311.01453*, 2024, doi: 10.48550/arXiv.2311.01453.
- [2] S. Wolfert, L. Ge, C. Verdouw, and M.-J. Bogaardt, "Big data in smart farming – A review," *Agric. Syst.*, vol. 153, pp. 69–80, May 2017, doi: 10.1016/j.agry.2017.01.023.
- [3] A. Kamilaris and F. X. Prenafeta-Boldú, "A review of the use of convolutional neural networks in agriculture," *J. Agric. Sci.*, vol. 156, no. 3, pp. 312–322, Jun. 2018, doi: 10.1017/S0021859618000436.
- [4] Z. Cao, S. Sun, and X. Bao, "A review of computer vision and deep learning applications in crop growth management," *Appl. Sci.*, vol. 15, no. 15. Art. no. 8438,

- Jul. 2025. doi: 10.3390/app15158438.
- [5] B. W. Ligar, "Computer vision for identifying and classifying green coffee beans: A review," *J. CoreIT J. Has. Penelit. Ilmu Komput. Teknol. Inf.*, vol. 8, no. 1, pp. 11–18, Jun. 2022, doi: 10.24014/coreit.v8i1.17450.
- [6] M. Ashfaq, I. Khan, D. Shah, S. Ali, and M. Tahir, "Predicting wheat yield using deep learning and multi-source environmental data," *Sci. Rep.*, vol. 15, Art. no. 26446, Jul. 2025, doi: 10.1038/s41598-025-11780-7.
- [7] S. Khaki and L. Wang, "Crop yield prediction using deep neural networks," *Front. Plant Sci.*, vol. 10, Art. no. 621, May 2019, doi: 10.3389/fpls.2019.00621.
- [8] T. Klompenburg, A. Kassahun, and C. Catal, "Crop yield prediction using machine learning: A systematic literature review," *Comput. Electron. Agric.*, vol. 177, Art. no. 105709, Oct. 2020, doi: 10.1016/j.compag.2020.105709.
- [9] C. A. M. Abreu Júnior *et al.*, "Estimating coffee plant yield based on multispectral images and machine learning models," *Agronomy*, vol. 12, no. 12, Art. no. 3195, Dec. 2022. doi: 10.3390/agronomy12123195.
- [10] W. Zhang *et al.*, "Deep-learning-based in-field citrus fruit detection and tracking," *Hortic. Res.*, vol. 9, Art. no. uhac003, Feb. 2022, doi: 10.1093/hr/uhac003.
- [11] B. D. S. Barbosa, G. A. e S. Ferraz, L. Costa, Y. Ampatzidis, V. Vijayakumar, and L. M. dos Santos, "UAV-based coffee yield prediction utilizing feature selection and deep learning," *Smart Agric. Technol.*, vol. 1, Art. no. 100010, Dec. 2021, doi: 10.1016/j.atech.2021.100010.
- [12] A. Sharifi, "Yield prediction with machine learning algorithms and satellite images," *J. Sci. Food Agric.*, vol. 101, no. 3, pp. 891–896, Feb. 2021, doi: 10.1002/jsfa.10696.
- [13] X. Li *et al.*, "Estimation of soybean yield based on high-throughput phenotyping and machine learning," *Front. Plant. Sci.*, vol. 15, Art. no. 1395760, Jun. 2024, doi: 10.3389/fpls.2024.1395760.
- [14] X. Hu *et al.*, "TasselNetV4: A vision foundation model for cross-scene, cross-scale, and cross-species plant counting," *ISPRS J. Photogramm. Remote Sens.*, vol. 231, pp. 745–760, Jan. 2026, doi: 10.1016/j.isprsjprs.2025.11.017.
- [15] F. Eron, M. Noman, R. R. de Oliveira, and A. Chalfun-Junior, "Computer vision-aided intelligent monitoring of coffee: Towards sustainable coffee production," *Sci. Hortic.*, vol. 327, Art. no. 112847, 2024. doi: 10.1016/j.scienta.2024.112847.
- [16] F. Palacios, M. P. Diago, P. Melo-Pinto, and J. Tardaguila, "Early yield prediction in different grapevine varieties using computer vision and machine learning," *Precis. Agric.*, vol. 24, no. 2, pp. 407–435, 2023, doi: 10.1007/s11119-022-09950-y.
- [17] T. Zrníc and E. J. Candès, "Cross-prediction-powered inference," *Proc. Natl. Acad. Sci.*, vol. 121, no. 15, Art. no. e2322083121, 2024, doi: 10.1073/pnas.2322083121.
- [18] S. Arwatchananukul, D. Xu, P. Charoenkwan, S. A. Moon, and R. Saengrayap, "Implementing a deep learning model for defect classification in Thai Arabica green coffee beans," *Smart Agric. Technol.*, vol. 9, Art. no. 100680, Nov. 2024, doi: 10.1016/j.atech.2024.100680.
- [19] A. A. Maulana, "Sistem deteksi otomatis buah berbasis computer vision menggunakan YOLO," in *Pros. Semin. Nas. Teknol. Sains (STAINS)*, Kediri, Indonesia, Jan. 24, 2026, vol. 5, no.1, pp. 431–438, doi: 10.25077/jfu.15.1.57-69.2026.
- [20] C. Zhang and J. M. Kovacs, "The application of small unmanned aerial systems for precision agriculture: A review," *Precis. Agric.*, vol. 13, no. 6, pp. 693–712, 2012, doi: 10.1007/s11119-012-9274-5.
- [21] A. F. Solis Pino and L. S. Caicedo Apraez, "Artificial intelligence and multispectral imaging in coffee production: A systematic literature review," *Eur. J. Agron.*, vol. 170, Art. no. 127725, Sep. 2025, doi: 10.1016/j.eja.2025.127725.

- [22] H. H. Li, M. Irgau, N. Janmohamed, K. S. Rieckmann, and D. B. Lobell, “Scalable vision-guided crop yield estimation,” in *Proc. AAAI Conf. Artif. Intell.*, Singapore, Jan. 20–27, 2026, vol. 40, no. 1, pp. 615–622, doi: 10.1609/aaai.v40i1.37026.
- [23] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, “Machine learning in agriculture: A review,” *Sensors*, vol. 18, no. 8, Art. no. 2674, 2018, doi: 10.3390/s18082674.
- [24] C. H. de Freitas, R. D. Coelho, J. de O. Costa, and P. C. Sentelhas, “Smart coffee: Machine learning techniques for estimating Arabica coffee yield,” *AgriEngineering*, vol. 6, no. 4, pp. 4925–4942, 2024, doi: 10.3390/agriengineering6040281.
- [25] R. O. Almeida, R. B. G. da Silva, and D. Simões, “Cut-to-length harvesting prediction tool: Machine learning model based on harvest and weather features,” *Forests*, vol. 15, no. 8, Art. no. 1398, 2024, doi: 10.3390/f15081398.
- [26] Z. Jin *et al.*, “A transformer-based symmetric diffusion segmentation network for wheat growth monitoring and yield counting,” *Agriculture*, vol. 15, no. 7, Art. no. 670, 2025, doi: 10.3390/agriculture15070670.