



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 24276-24286

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Klasifikasi Kematangan Stroberi Menggunakan OpenCV, CNN EfficientNet-B0, dan Grad-CAM Berbasis Web

Dion Arifin, Tomi Tri Sujaka, I Nyoman Switrayana

Ilmu Komputer, Fakultas Teknik, Universitas Bumigora

hello.dionarifin@gmail.com

Abstrak

Penilaian tingkat kematangan buah stroberi secara manual bersifat subjektif, memerlukan pengalaman, dan memakan waktu, sehingga dibutuhkan sistem klasifikasi otomatis yang akurat, transparan, serta mudah diakses. Penelitian ini mengembangkan sistem klasifikasi tingkat kematangan stroberi berbasis web dengan memanfaatkan Open Source Computer Vision Library (OpenCV) untuk pemrosesan citra dan Convolutional Neural Network berarsitektur EfficientNet-B0 melalui transfer learning dengan strategi partial fine-tuning. Dataset terdiri atas 677 citra stroberi yang diperoleh dari Kecamatan Sembalun, Kabupaten Lombok Timur, dan repositori publik, kemudian dikelompokkan ke dalam kelas "Dapat Dipetik" dan "Tidak Dapat Dipetik". Data dibagi menggunakan stratified random sampling melalui tiga skenario rasio latih, validasi, dan uji, yaitu 80:10:10, 70:15:15, dan 60:20:20. Transparansi keputusan model diwujudkan melalui Gradient-weighted Class Activation Mapping (Grad-CAM) yang diproses bersama OpenCV untuk menghasilkan heatmap dan overlay. Sistem dikembangkan menggunakan FastAPI, dikemas melalui Docker, dan disebarluaskan pada Hugging Face Spaces. Hasil pengujian menunjukkan bahwa rasio 80:10:10 menghasilkan kinerja paling stabil dengan akurasi validasi akhir sebesar 97,79% dan F1-score rata-rata tertimbang sebesar 97,79%. Visualisasi Grad-CAM menunjukkan bahwa model berfokus pada tekstur dan pigmentasi buah, bukan pada latar belakang. Temuan ini menunjukkan bahwa integrasi EfficientNet-B0, Grad-CAM, OpenCV, dan layanan web mampu menyediakan klasifikasi kematangan stroberi yang akurat, dapat dijelaskan, responsif, dan berpotensi mendukung pengambilan keputusan panen.

Kata kunci: Stroberi, Pengolahan Citra Digital, Convolutional Neural Network, EfficientNet-B0, Grad-CAM

1. Pendahuluan

Stroberi merupakan salah satu komoditas hortikultura dengan tingkat konsumsi tinggi karena rasanya yang khas serta kandungan gizinya, termasuk vitamin C, antioksidan, dan senyawa bioaktif yang bermanfaat bagi kesehatan (Afrin et al., 2016). Produksi stroberi nasional Indonesia menunjukkan tren pertumbuhan yang signifikan, dan Kecamatan Sembalun di Kabupaten Lombok Timur merupakan salah satu sentra produksi utama yang didukung oleh kondisi geografis dataran tinggi yang sesuai untuk budidaya stroberi (Setiawan et al., 2026). Meskipun prospek usahatani di kawasan ini tergolong layak, petani masih menghadapi kendala perubahan iklim, fluktuasi harga, dan keterbatasan akses informasi (Hapsari et al., 2025).

Tingkat kematangan buah menjadi salah satu faktor penentu kualitas dan daya saing produk di pasar. Namun demikian, proses penentuan waktu panen di lapangan masih didominasi oleh penilaian manual yang bergantung pada pengalaman dan penilaian subjektif operator, sehingga rentan terhadap human error (Mi & Yan, 2024). Perkembangan *Computer Vision* dan *Deep Learning* membuka peluang untuk mengatasi permasalahan tersebut secara lebih efektif. *Open Source Computer Vision Library* (OpenCV) banyak dimanfaatkan pada tahap pra-pemrosesan citra karena kemampuannya melakukan analisis secara real-time (Wan Hamri & Jabbar, 2024), sementara *Convolutional Neural Network* (CNN) telah terbukti memberikan kinerja yang baik pada tugas klasifikasi citra buah, termasuk stroberi (Yang & Xu, 2021).

Penelitian terdahulu telah menunjukkan hasil yang menjanjikan pada klasifikasi kematangan stroberi berbasis CNN, di antaranya penggunaan convolution-based feature extractor dengan prosesor AI edge berbasis FPGA yang mencapai akurasi 93,4% (Park et al., 2024), serta kombinasi model deteksi objek dengan augmented reality untuk identifikasi real-time di lapangan yang mencapai F1-Score 0,92 (Chai et al., 2023). Walaupun demikian, sebagian besar penelitian tersebut masih berorientasi pada peningkatan akurasi tanpa memberikan penjelasan mengenai

dasar pengambilan keputusan model (*black-box problem*), sehingga tingkat kepercayaan pengguna di sektor pertanian terhadap hasil klasifikasi dapat berkurang apabila prediksi tidak sejalan dengan pengalaman lapangan mereka (von Eschenbach, 2021). Di samping itu, penelitian yang telah ada juga umumnya masih terbatas pada pengembangan model tanpa mengimplementasikannya sebagai layanan yang dapat diakses secara langsung melalui platform berbasis web.

Kesenjangan tersebut menunjukkan belum tersedianya sistem klasifikasi tingkat kematangan stroberi yang sekaligus memiliki akurasi tinggi, bersifat transparan (*explainable*), dan mudah diakses secara daring. Penelitian ini menjawab kesenjangan tersebut dengan menerapkan pendekatan *Explainable AI* menggunakan Grad-CAM untuk memvisualisasikan area citra yang menjadi dasar keputusan model (von Eschenbach, 2021), dan mengimplementasikan sistem klasifikasi berbasis *EfficientNet-B0* sebagai layanan web yang dapat diakses tanpa memerlukan perangkat keras khusus (Tan & Le, 2019). Dengan demikian, penelitian ini bertujuan mengevaluasi efektivitas arsitektur *EfficientNet-B0* dalam mengklasifikasikan tingkat kematangan buah stroberi, mengimplementasikan Grad-CAM untuk memberikan transparansi visual atas keputusan klasifikasi, serta merancang dan menguji sistem layanan berbasis web yang dapat dimanfaatkan secara praktis oleh petani dan pelaku industri pertanian, khususnya di Kecamatan Sembalun sebagai lokasi penelitian.

2. Metode Penelitian

Penelitian ini diawali dengan studi literatur mengenai arsitektur *EfficientNet*, *Transfer Learning*, dan *Explainable AI*, dilanjutkan dengan pengumpulan data, pembagian data, pra-pemrosesan, pelatihan model, evaluasi, implementasi Grad-CAM, hingga pengembangan dan *deployment* sistem berbasis web.

2.1 Dataset dan Pembagian Data

Dataset terdiri atas 677 citra stroberi RGB yang dikumpulkan dari dua sumber, yaitu data primer hasil pengambilan langsung di perkebunan Kecamatan Sembalun menggunakan kamera ponsel pintar, dan data sekunder dari repositori publik Kaggle. Seluruh citra dikelompokkan ke dalam dua kelas, yaitu “Dapat Dipetik” (matang) dan “Tidak Dapat Dipetik” (mentah, setengah matang, atau busuk), dengan rincian distribusi pada Tabel 1.

Tabel 1. Distribusi Dataset Citra Stroberi

Kelas	Keterangan	Jumlah
Dapat Dipetik	Matang, merah penuh	347
Tidak Dapat Dipetik	Mentah / hijau-putih / busuk	330
Total		677



Gambar 1. Sampel citra dataset stroberi gabungan

Dataset dibagi menggunakan teknik *Stratified Random Sampling* agar proporsi tiap kelas tetap konsisten pada setiap subset. Untuk menentukan konfigurasi pembagian data yang paling optimal, dirancang tiga skenario rasio latih:validasi:uji yang dibandingkan, yaitu 80:10:10, 70:15:15, dan 60:20:20, dengan konfigurasi hiperparameter pelatihan yang identik pada ketiga skenario sehingga perbedaan hasil hanya dapat dikaitkan dengan perbedaan rasio pembagian data.

2.2 Pra-pemrosesan dan Augmentasi Data

Setiap citra distandarisasi melalui pustaka torchvision.transforms, meliputi resizing menjadi 256 piksel yang dilanjutkan dengan center crop menjadi 224×224 piksel sesuai spesifikasi input EfficientNet-B0, kemudian dinormalisasi menggunakan mean [0,485, 0,456, 0,406] dan standar deviasi [0,229, 0,224, 0,225] dari dataset ImageNet. Untuk menguji pengaruh augmentasi terhadap generalisasi model, dilakukan eksperimen perbandingan antara model yang dilatih dengan augmentasi (Random Horizontal/Vertical Flip, Random Rotation, Random Affine, Color Jitter, Gaussian Blur, Random Perspective, dan Random Resized Crop) dan model tanpa augmentasi sebagai baseline, yang diterapkan secara eksklusif pada data latih untuk mencegah kebocoran data ke subset validasi dan uji.

2.3 Arsitektur Model dan Pelatihan

Model klasifikasi dibangun menggunakan arsitektur EfficientNet-B0 (Tan & Le, 2019) sebagai backbone melalui metode Transfer Learning dengan bobot awal dari ImageNet. Strategi Partial Fine-Tuning diterapkan dengan membekukan lapisan-lapisan awal backbone, sementara dua puluh parameter terakhir beserta classifier head tetap diperbarui selama pelatihan. Model dilatih selama 30 epoch menggunakan optimizer Adam dengan learning rate 0,001 dan fungsi kerugian CrossEntropyLoss dengan label smoothing 0,1, untuk menghasilkan klasifikasi biner “Dapat Dipetik” dan “Tidak Dapat Dipetik”.

2.4 Explainable AI Berbasis Grad-CAM dan OpenCV

Untuk memberikan transparansi atas keputusan model, diterapkan Gradient-weighted Class Activation Mapping (Grad-CAM) (Selvaraju et al., 2017) yang menghitung gradien kelas target terhadap peta fitur pada lapisan konvolusi terakhir EfficientNet-B0 menggunakan PyTorch. Pustaka OpenCV (Bradski, 2000) kemudian berperan dalam tiga tahap pasca-inferensi secara berurutan: cv2.applyColorMap() untuk mengubah peta gradien menjadi representasi warna COLORMAP_JET, cv2.resize() untuk menyesuaikan dimensi heatmap dengan citra asli, dan cv2.addWeighted() untuk menggabungkan heatmap dengan citra asli menggunakan bobot $\alpha=0,6$ pada citra asli dan $\beta=0,4$ pada heatmap sehingga menghasilkan visualisasi overlay yang mudah dipahami pengguna.

2.5 Implementasi Sistem dan Deployment

Antarmuka pengguna (frontend) dikembangkan berbasis HTML5 dan JavaScript sebagai Single Page Application yang mendukung unggah citra melalui klik maupun drag and drop, serta menampilkan hasil prediksi melalui tab visualisasi Original, Heatmap, dan Overlay. Layanan backend dibangun menggunakan kerangka kerja FastAPI yang menjalankan proses inferensi model dan Grad-CAM. Sistem dikemas menggunakan Docker untuk menjaga konsistensi dependensi pustaka, khususnya OpenCV, antara lingkungan pengembangan dan server, kemudian disebarkan pada layanan cloud Hugging Face Spaces agar dapat diakses secara publik melalui protokol HTTPS.

2.6 Metrik Evaluasi

Kinerja model dievaluasi menggunakan Confusion Matrix serta metrik Accuracy, Precision, Recall, dan F1-Score pada data validasi dan data uji. Konfigurasi rasio pembagian data dengan performa terbaik dan paling stabil ditetapkan sebagai model final yang digunakan pada tahap implementasi sistem, sementara fungsionalitas aplikasi web diverifikasi melalui pengujian Black Box.

3. Hasil dan Diskusi

3.1 Perbandingan Skenario Pembagian Data

Ketiga skenario rasio pembagian data dilatih dengan konfigurasi hiperparameter yang identik agar perbedaan hasil hanya dapat dikaitkan dengan rasio pembagian data. Ringkasan perbandingan kinerja ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Kinerja Tiga Skenario Rasio Pembagian Data

Rasio	Best Epoch	Val. Acc.	F1-Score
80:10:10	16	98,53%	0,99
60:20:20	1*	100,00%*	0,97
70:15:15	1*	100,00%*	0,97

*) Best Epoch = 1 dan Best Val Accuracy = 100% pada rasio 60:20:20 dan 70:15:15 merupakan anomali yang disebabkan oleh distribusi validation set yang terlalu mudah diprediksi pada epoch pertama, sehingga hasilnya tidak dapat diandalkan.


Rasio 80:10:10 ditetapkan sebagai konfigurasi final karena menghasilkan pola konvergensi paling stabil, dengan best epoch tercapai pada epoch ke-16 sehingga model belajar secara bertahap, serta memaksimalkan jumlah data latih yang penting mengingat ukuran dataset penelitian yang relatif terbatas (677 citra).

3.2 Pengaruh Augmentasi Data

Berdasarkan hasil evaluasi, penerapan teknik augmentasi data tidak memberikan peningkatan performa yang signifikan. Validation accuracy terbaik model tanpa augmentasi dan dengan augmentasi sama-sama mencapai 98,53%, namun model tanpa augmentasi menunjukkan hasil yang lebih stabil pada kelas “Dapat Dipetik” (98,48%) dibandingkan model dengan augmentasi (96,97%). Ketidakstabilan tersebut diduga terjadi karena transformasi yang terlalu agresif mendistorsi fitur visual halus pada tekstur stroberi yang krusial bagi model, sehingga konfigurasi tanpa augmentasi ditetapkan sebagai model final.

3.3 Evaluasi Kinerja Model Akhir

Model EfficientNet-B0 dengan rasio 80:10:10 mencapai akurasi validasi akhir sebesar 97,79%. Dari total citra evaluasi, model berhasil memprediksi benar sebagian besar sampel dan hanya melakukan kesalahan pada sejumlah kecil citra, dengan rincian True Positive 64, True Negative 69, False Positive 1, dan False Negative 2. Rincian metrik presisi, recall, dan F1-Score per kelas ditunjukkan pada Tabel 3.



Gambar 2. Visualisasi Confusion Matrix


Tabel 3. Laporan Kinerja Klasifikasi Model

Kelas	Precision	Recall	F1-Score
Dapat Dipetik	98,46%	96,97%	97,71%
Tidak Dapat Dipetik	97,18%	98,57%	97,87%
Rata-rata Tertimbang	97,80%	97,79%	97,79%

Presisi tinggi pada kelas “Dapat Dipetik” (98,46%) menunjukkan bahwa ketika sistem memberi label “matang”, tingkat kepercayaan kebenarannya sangat tinggi sehingga meminimalkan risiko panen buah mentah. Recall tinggi pada kelas “Tidak Dapat Dipetik” (98,57%) menunjukkan model efektif menyaring buah yang belum layak panen. F1-Score yang hampir identik pada kedua kelas ($\approx 97,8\%$) membuktikan model tidak bias terhadap salah satu kategori. Analisis kualitatif terhadap citra yang salah diklasifikasikan menunjukkan bahwa kesalahan umumnya terjadi pada stroberi dalam fase transisi (setengah matang) dengan gradasi warna merah-putih yang tercampur, serta pada citra dengan pencahayaan yang terlalu kontras sehingga tekstur permukaan buah kurang jelas.

3.4 Analisis Visual Explainable AI (Grad-CAM)

Evaluasi kualitatif menggunakan Grad-CAM dilakukan untuk memvalidasi bahwa model mengenali objek stroberi berdasarkan fitur yang relevan, bukan berdasarkan bias latar belakang. Perbandingan visualisasi citra asli, heatmap, dan overlay ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi Grad-CAM: (kiri) kelas “Dapat Dipetik”, (kanan) kelas “Tidak Dapat Dipetik”

Pada kelas “Dapat Dipetik”, area beraktivasi tinggi (merah menyala) terkonsentrasi tepat pada permukaan daging buah berwarna merah, khususnya pada tekstur berbintik (achenes) dan pigmentasi merah, sementara area daun dan latar belakang tanah menunjukkan aktivasi rendah. Hal ini memvalidasi bahwa model belajar mengasosiasikan warna merah dominan sebagai indikator utama kematangan. Pada kelas “Tidak Dapat Dipetik”, heatmap menyoroti area buah berwarna putih kehijauan, termasuk pada bagian ujung yang masih putih pada buah setengah matang, yang menjadi penentu bahwa buah belum layak petik. Konsistensi area fokus ini membuktikan bahwa prediksi model didasarkan pada fitur fisik buah, bukan pada noise citra.

3.5 Pengujian Fungsional dan Implementasi Sistem Web

Pengujian Black Box dilakukan untuk memverifikasi bahwa fitur-fitur aplikasi web, meliputi validasi input, prediksi citra, serta fitur visualisasi interaktif (tab Original, Heatmap, dan Overlay), berjalan sesuai spesifikasi kebutuhan. Seluruh skenario pengujian dinyatakan valid. Sistem selanjutnya dikemas menggunakan Docker untuk menjaga konsistensi dependensi OpenCV pada lingkungan tanpa antarmuka grafis (headless), kemudian disebarkan pada Hugging Face Spaces dan dapat diakses secara publik melalui protokol HTTPS. Pengujian aksesibilitas pada perangkat seluler menunjukkan bahwa antarmuka web responsif dan fungsi prediksi berjalan normal, sebagaimana halnya pada komputer desktop.

3.6 Perbandingan dengan Penelitian Terdahulu

Perbandingan kinerja penelitian ini dengan beberapa penelitian klasifikasi kematangan buah berbasis CNN sebelumnya ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan dengan Penelitian Terdahulu

Penulis (Tahun)	Metode	Akurasi
Dhiman et al. (2025)	YOLOv8 & InceptionV3	95,40%

Penulis (Tahun)	Metode	Akurasi
Tassis et al. (2024)	Light-MobileBerryNet	96,60%
Iqbal et al. (2023)	FANN + fitur CIELab	96,70%
Miao et al. (2023)	Mask R-CNN + Region Seg.	94,00%
Penelitian Ini (2026)	EfficientNet-B0 + Grad-CAM	97,79%

Metode yang diusulkan pada penelitian ini unggul secara akurasi dibandingkan sejumlah metode terbaru lainnya. Keunggulan utama penelitian ini terletak pada penerapan Grad-CAM yang memberikan transparansi visual atas keputusan model, fitur Explainable AI yang belum menjadi fokus pada sebagian besar penelitian pembandingan. Kontribusi metodologis lain adalah pelaksanaan eksperimen perbandingan tiga rasio pembagian data yang menghasilkan temuan bahwa rasio 80:10:10 memberikan kinerja paling stabil pada ukuran dataset yang terbatas, yang dapat menjadi referensi metodologis bagi penelitian klasifikasi buah berbasis CNN dengan dataset kecil serupa di masa mendatang.

3.7 Stabilitas Pembagian Data dan Kemampuan Generalisasi Model

Pemilihan rasio 80:10:10 sebagai konfigurasi akhir perlu dipahami tidak hanya berdasarkan nilai akurasi tertinggi, tetapi juga berdasarkan pola pembelajaran yang lebih wajar dan stabil. Pada rasio 60:20:20 dan 70:15:15, akurasi validasi sebesar 100% telah muncul pada epoch pertama. Dalam konteks dataset yang hanya terdiri atas 677 citra, capaian tersebut lebih tepat dibaca sebagai indikasi bahwa subset validasi tertentu relatif mudah dikenali, bukan sebagai bukti bahwa model telah membentuk representasi visual yang sepenuhnya general. Sebaliknya, konfigurasi 80:10:10 mencapai best epoch pada epoch ke-16 dan menunjukkan proses konvergensi yang berlangsung secara bertahap. Pola tersebut memberikan dasar yang lebih kuat untuk memilih model karena peningkatan performa terjadi setelah proses pembaruan bobot yang memadai, bukan akibat keberuntungan komposisi subset validasi. Penggunaan stratified random sampling telah menjaga proporsi dua kelas pada setiap subset, tetapi teknik ini tidak serta-merta menjamin bahwa tingkat kesulitan visual setiap subset sama. Citra dengan pencahayaan seragam, objek yang dominan, atau warna kematangan yang sangat tegas dapat membuat subset tertentu lebih mudah diprediksi meskipun distribusi kelasnya seimbang.

Rasio 80:10:10 juga memberi keuntungan berupa porsi data latih yang lebih besar. Hal ini penting karena transfer learning tetap membutuhkan jumlah contoh yang cukup agar lapisan yang dibuka pada tahap partial fine-tuning dapat menyesuaikan fitur umum dari ImageNet terhadap karakteristik khusus stroberi. EfficientNet-B0 dirancang melalui penskalaan kedalaman, lebar, dan resolusi secara seimbang, sehingga relatif efisien untuk tugas klasifikasi citra (Tan & Le, 2019). Namun, efisiensi arsitektur tidak menghilangkan risiko overfitting ketika jumlah data terbatas. Oleh sebab itu, stabilitas kurva pelatihan menjadi pertimbangan yang sama pentingnya dengan nilai akurasi akhir. Temuan penelitian ini memperlihatkan bahwa rasio dengan data latih paling besar justru menghasilkan proses pembelajaran yang lebih meyakinkan, sedangkan dua rasio lain memperlihatkan nilai sempurna yang terlalu dini. Hasil tersebut sejalan dengan prinsip umum bahwa performa deep learning sangat dipengaruhi oleh keragaman dan representativitas data, khususnya pada aplikasi hortikultura yang memiliki variasi warna, tekstur, bentuk, kondisi cahaya, dan latar belakang (Yang & Xu, 2021).

Meskipun demikian, kesimpulan mengenai keunggulan rasio 80:10:10 masih terbatas pada tiga pembagian data yang digunakan dalam penelitian ini. Nilai performa dapat berubah apabila seed acak, komposisi citra, atau sumber data diubah. Karena itu, interpretasi hasil sebaiknya menekankan bahwa rasio 80:10:10 merupakan konfigurasi paling stabil dalam eksperimen yang dilakukan, bukan rasio universal untuk seluruh dataset klasifikasi buah. Penelitian lanjutan dapat memperkuat validitas dengan repeated stratified split, stratified k-fold cross-validation, atau pengujian pada dataset eksternal yang berasal dari kebun dan perangkat kamera berbeda. Pengujian tersebut akan membantu memisahkan kemampuan model dalam mengenali karakteristik kematangan dari kemungkinan ketergantungan terhadap pola spesifik sumber data. Dengan pendekatan tersebut, generalisasi model dapat dinilai secara lebih menyeluruh sebelum sistem digunakan sebagai pendukung keputusan panen pada kondisi lapangan yang heterogen.

3.8 Interpretasi Kesalahan Klasifikasi dan Karakteristik Visual Stroberi

Confusion matrix menunjukkan bahwa model menghasilkan 64 true positive, 69 true negative, satu false positive, dan dua false negative. Jumlah kesalahan yang rendah mendukung nilai akurasi 97,79%, tetapi analisis terhadap jenis kesalahan memberikan informasi yang lebih bermakna dibandingkan sekadar nilai agregat. False positive menunjukkan kondisi ketika buah yang seharusnya belum dapat dipetik diprediksi sebagai dapat dipetik. Dalam praktik panen, kesalahan ini berpotensi menyebabkan buah dipanen terlalu awal atau buah dengan kondisi tidak sesuai masuk ke kelompok matang. Sebaliknya, false negative membuat buah yang sebenarnya layak dipetik dikategorikan sebagai belum layak, sehingga berpotensi menunda panen. Presisi kelas “Dapat Dipetik” sebesar 98,46% menunjukkan bahwa rekomendasi matang yang diberikan sistem memiliki tingkat ketepatan tinggi, sedangkan recall kelas “Tidak Dapat Dipetik” sebesar 98,57% menunjukkan kemampuan model yang kuat dalam menyaring buah yang belum sesuai untuk dipanen. Keseimbangan F1-score kedua kelas memperlihatkan bahwa model tidak hanya mengejar performa pada salah satu kelas.

Kesalahan terutama muncul pada buah dalam fase transisi yang memiliki gradasi merah dan putih serta pada citra dengan pencahayaan kontras. Temuan ini dapat dijelaskan melalui sifat visual proses pematangan stroberi yang berlangsung secara kontinu, sedangkan label penelitian dibentuk secara biner. Kelas “Tidak Dapat Dipetik” menggabungkan buah mentah, setengah matang, dan busuk, padahal ketiga kondisi tersebut dapat memiliki karakteristik visual yang berbeda. Buah setengah matang memiliki sebagian pigmentasi merah yang juga menjadi fitur penting kelas matang, sedangkan buah busuk dapat menampilkan warna gelap atau tekstur tertentu yang tidak sama dengan buah mentah. Penggabungan beberapa kondisi ke dalam satu kelas memudahkan implementasi keputusan “petik atau tidak petik”, tetapi sekaligus menciptakan variasi intra-kelas yang lebih besar. Penelitian deteksi kematangan stroberi lain juga menunjukkan bahwa perubahan warna, tingkat penutupan warna merah, dan kondisi oklusi merupakan faktor penting yang memengaruhi klasifikasi (Chai et al., 2023; Mi & Yan, 2024).

Pencahayaan yang terlalu kuat atau tidak merata dapat mengubah persepsi warna, menghilangkan detail tekstur, dan menghasilkan pantulan pada permukaan buah. Kondisi tersebut dapat menggeser distribusi piksel dari pola yang dipelajari model, meskipun objek secara semantik masih merupakan stroberi yang sama. Oleh karena itu, peningkatan performa pada tahap berikutnya tidak cukup dilakukan hanya dengan menambah jumlah citra, tetapi juga harus memperluas variasi kondisi pengambilan gambar. Dataset tambahan sebaiknya mencakup cahaya pagi, siang, sore, bayangan daun, latar belakang tanah, tangan operator, buah yang saling menutupi, serta beragam jarak dan sudut kamera. Penambahan kelas transisi juga dapat dipertimbangkan agar sistem tidak memaksa seluruh buah setengah matang ke dalam keputusan biner yang terlalu kasar. Alternatif lain adalah mempertahankan keluaran biner untuk pengguna, tetapi melatih model dengan kelas yang lebih rinci dan kemudian memetakan beberapa kelas tersebut ke keputusan operasional “dapat dipetik” atau “tidak dapat dipetik”. Pendekatan ini berpotensi mempertahankan kesederhanaan antarmuka sekaligus meningkatkan sensitivitas model terhadap tahapan kematangan.

3.9 Kesesuaian EfficientNet-B0 dan Strategi Partial Fine-Tuning

Penggunaan EfficientNet-B0 merupakan pilihan yang relevan untuk penelitian ini karena arsitektur tersebut menawarkan kompromi antara akurasi dan kebutuhan komputasi. EfficientNet memperkenalkan compound scaling yang menyeimbangkan kedalaman jaringan, lebar jaringan, dan resolusi input, sehingga peningkatan kapasitas model dilakukan secara terstruktur (Tan & Le, 2019). Pada dataset berukuran terbatas, penggunaan bobot awal ImageNet membantu model memanfaatkan fitur visual umum yang telah dipelajari dari data berskala besar. Fitur awal seperti tepi, kontur, tekstur, dan pola warna dapat ditransfer ke citra stroberi, sedangkan lapisan yang dibuka pada partial fine-tuning menyesuaikan representasi tersebut terhadap karakteristik kematangan. Strategi ini lebih efisien dibandingkan melatih seluruh jaringan dari awal karena jumlah parameter yang perlu diperbarui menjadi lebih terkendali dan risiko pembelajaran yang tidak stabil dapat dikurangi.

Pembekuan lapisan awal dan pembaruan dua puluh parameter terakhir beserta classifier head menunjukkan bahwa penelitian berupaya mempertahankan pengetahuan umum model sekaligus menyediakan ruang adaptasi pada lapisan tingkat tinggi. Secara konseptual, lapisan awal CNN cenderung menangkap pola visual dasar, sedangkan lapisan yang lebih dalam membentuk representasi yang lebih spesifik terhadap objek dan kelas. Keputusan untuk melakukan partial fine-tuning sesuai dengan kebutuhan dataset stroberi yang memiliki ciri dominan berupa pigmentasi merah, area putih kehijauan, tekstur permukaan, dan bentuk buah. Komponen seperti squeeze-and-excitation yang menjadi bagian penting dalam keluarga EfficientNet membantu memberikan bobot berbeda terhadap saluran fitur, sehingga informasi visual yang lebih relevan dapat diperkuat (Hu et al., 2018). Aktivasi

yang efisien dan blok konvolusi ringan juga mendukung penggunaan model pada layanan web yang perlu merespons permintaan pengguna tanpa perangkat keras khusus yang sangat besar.

Akurasi penelitian ini lebih tinggi daripada beberapa metode pembandingan pada Tabel 4, tetapi perbandingan lintas penelitian harus ditafsirkan secara hati-hati. Setiap penelitian dapat menggunakan jumlah citra, definisi kelas, kondisi lapangan, strategi pembagian data, dan metrik evaluasi yang berbeda. Oleh karena itu, selisih akurasi tidak secara langsung membuktikan bahwa EfficientNet-B0 selalu lebih unggul daripada YOLOv8, InceptionV3, Mask R-CNN, atau metode berbasis fitur warna. Kontribusi yang lebih kuat dari penelitian ini terletak pada integrasi model klasifikasi, evaluasi beberapa skenario pembagian data, interpretasi Grad-CAM, dan deployment berbasis web. Untuk membuktikan keunggulan arsitektur secara lebih ketat, penelitian berikutnya perlu membandingkan beberapa backbone pada dataset dan protokol evaluasi yang sama. MobileNetV2 dapat digunakan sebagai pembandingan ringan karena dirancang dengan inverted residual dan linear bottleneck (Sandler et al., 2018), sedangkan arsitektur lain dapat dipilih untuk menguji apakah peningkatan performa sebanding dengan penambahan parameter dan waktu inferensi.

Konfigurasi pelatihan selama 30 epoch, optimizer Adam, learning rate 0,001, CrossEntropyLoss, dan label smoothing 0,1 telah menghasilkan model yang stabil pada rasio 80:10:10. Namun, penelitian belum melaporkan eksperimen ablation untuk mengukur kontribusi masing-masing komponen. Belum dapat dipastikan seberapa besar peningkatan yang berasal dari partial fine-tuning, label smoothing, pemilihan optimizer, atau bobot awal ImageNet. Eksperimen lanjutan dapat membandingkan pelatihan classifier head saja, partial fine-tuning dengan jumlah lapisan berbeda, dan full fine-tuning. Selain itu, evaluasi calibration error dapat digunakan untuk menilai apakah probabilitas prediksi benar-benar merepresentasikan tingkat keyakinan model. Informasi kalibrasi penting apabila sistem akan digunakan untuk memberikan rekomendasi panen, karena pengguna membutuhkan bukan hanya label kelas, tetapi juga indikator ketidakpastian ketika citra berada pada fase transisi atau memiliki kualitas visual rendah.

3.10 Transparansi Keputusan melalui Grad-CAM dan OpenCV

Integrasi Grad-CAM memberikan dimensi interpretabilitas yang tidak tersedia apabila sistem hanya menampilkan label prediksi dan nilai probabilitas. Visualisasi pada Gambar 3 menunjukkan bahwa area aktivasi tinggi berada pada permukaan buah, terutama pigmentasi merah dan bagian putih kehijauan, sedangkan latar belakang memperoleh perhatian yang lebih rendah. Pola ini mendukung validitas perilaku model karena dasar keputusan selaras dengan ciri fisik kematangan yang dapat dipahami pengguna. Grad-CAM bekerja dengan memanfaatkan gradien kelas target terhadap peta fitur pada lapisan konvolusi terakhir untuk membentuk peta lokasi yang berkontribusi terhadap prediksi (Selvaraju et al., 2017). Dalam penelitian ini, OpenCV digunakan untuk memberi colormap, mengubah ukuran heatmap, dan membuat overlay sehingga informasi internal model dapat diterjemahkan menjadi tampilan visual yang mudah diamati.

Transparansi tersebut memiliki nilai praktis bagi petani dan pelaku industri pertanian. Apabila sistem memprediksi buah sebagai matang tetapi heatmap justru berfokus pada tanah, daun, label kemasan, atau objek lain, pengguna dapat meragukan hasil prediksi dan mengambil keputusan secara lebih hati-hati. Sebaliknya, fokus yang konsisten pada permukaan buah meningkatkan keyakinan bahwa model menggunakan fitur yang relevan. Hal ini penting karena masalah black box bukan hanya persoalan teknis, tetapi juga berkaitan dengan penerimaan pengguna. Sistem AI yang akurat belum tentu dipercaya apabila alasan di balik keputusannya tidak dapat dipahami, terutama ketika hasil model berbeda dengan pengalaman operator (von Eschenbach, 2021). Dengan demikian, Grad-CAM berfungsi sebagai sarana komunikasi antara model dan pengguna, bukan sekadar ilustrasi tambahan.

Walaupun demikian, heatmap Grad-CAM tidak boleh diperlakukan sebagai bukti kausal yang sempurna. Grad-CAM merupakan metode penjelasan post hoc yang menunjukkan area yang berkorelasi dengan prediksi, tetapi tidak menjamin bahwa seluruh proses internal model telah dijelaskan. Resolusi heatmap juga lebih kasar daripada citra asli karena dibentuk dari peta fitur lapisan konvolusi terakhir. Area merah yang luas dapat mencakup bagian buah dan latar yang berdekatan, sehingga interpretasinya tetap membutuhkan kehati-hatian. Oleh sebab itu, validasi explainability dapat diperkuat melalui pengujian kuantitatif, misalnya dengan menghapus atau menutupi area yang memperoleh aktivasi tinggi kemudian mengukur perubahan probabilitas prediksi. Konsistensi heatmap juga dapat diuji pada beberapa citra dengan kondisi pencahayaan, sudut, dan latar berbeda.

Penyajian tiga tab, yaitu Original, Heatmap, dan Overlay, merupakan keputusan antarmuka yang tepat karena pengguna dapat membandingkan citra masukan dengan hasil penjelasan secara langsung. Citra original

mempertahankan konteks visual, heatmap memperlihatkan intensitas perhatian, dan overlay menggabungkan keduanya agar lokasi fokus mudah dipahami. Pada implementasi lebih lanjut, sistem dapat menambahkan pesan interpretatif yang sederhana, misalnya “model berfokus pada area merah dominan” atau “hasil perlu diperiksa kembali karena area perhatian tersebar”. Pesan tersebut harus dihasilkan berdasarkan aturan yang transparan dan tidak boleh menggantikan penilaian pengguna. Dengan pendekatan tersebut, explainable AI dapat ditempatkan sebagai mekanisme pendukung pengawasan manusia, sehingga keputusan panen tetap mempertimbangkan kondisi fisik buah dan konteks lapangan.

3.11 Implikasi Implementasi Sistem Web bagi Penggunaan Lapangan

Pengembangan sistem dalam bentuk aplikasi web memperluas manfaat model dari sekadar eksperimen komputasi menjadi layanan yang dapat digunakan melalui perangkat umum. Frontend berbasis HTML5 dan JavaScript menyediakan mekanisme unggah citra melalui klik maupun drag and drop, sedangkan FastAPI menangani inferensi model dan pembentukan Grad-CAM pada sisi backend. Arsitektur ini memisahkan tampilan pengguna dari proses komputasi, sehingga pemeliharaan aplikasi dapat dilakukan secara lebih modular. Penggunaan Docker juga membantu menjaga konsistensi versi pustaka dan dependensi antara lingkungan pengembangan dan server. Aspek ini relevan bagi OpenCV karena beberapa fungsi pemrosesan citra dapat mengalami masalah kompatibilitas pada server tanpa antarmuka grafis. Kontainerisasi mengurangi perbedaan konfigurasi tersebut dan membuat proses deployment lebih dapat direplikasi.

Hasil pengujian black box menunjukkan bahwa fungsi validasi input, prediksi citra, dan visualisasi interaktif berjalan sesuai spesifikasi. Pengujian pada perangkat seluler juga menunjukkan bahwa antarmuka responsif dan proses prediksi dapat digunakan seperti pada komputer desktop. Temuan ini mendukung potensi penggunaan sistem di kebun, karena operator tidak harus membawa komputer khusus. Citra dapat diambil menggunakan kamera ponsel, kemudian dikirim ke aplikasi untuk memperoleh klasifikasi dan visualisasi. Model berbasis web juga memudahkan pembaruan karena versi model dapat diganti pada server tanpa menginstal ulang aplikasi pada setiap perangkat pengguna. Dalam konteks adopsi awal, karakteristik ini dapat menurunkan hambatan penggunaan teknologi AI pada sektor pertanian.

Namun, keberhasilan fungsi aplikasi belum secara otomatis menunjukkan kesiapan operasional dalam skala luas. Penelitian belum melaporkan waktu inferensi, latensi jaringan, jumlah pengguna serentak, konsumsi memori, ketersediaan layanan, atau ketahanan sistem ketika menerima citra berukuran besar dan format yang beragam. Deployment pada layanan cloud publik juga bergantung pada kualitas koneksi internet di lokasi pengguna. Pada wilayah kebun dengan sinyal tidak stabil, proses unggah dapat menjadi lambat atau gagal. Oleh sebab itu, evaluasi lanjutan perlu mencakup pengujian performa sistem, batas ukuran berkas, validasi keamanan, pencatatan kegagalan, dan mekanisme penanganan ketika layanan tidak tersedia. Pengukuran waktu dari unggah hingga hasil tampil juga penting untuk menilai apakah sistem benar-benar mendukung keputusan panen secara cepat.

Aplikasi sebaiknya diposisikan sebagai alat bantu, bukan sebagai satu-satunya dasar penentuan panen. Pengguna perlu memperoleh informasi mengenai kelas prediksi, tingkat keyakinan, heatmap, dan kondisi ketika hasil harus diperiksa ulang. Sistem juga dapat menyediakan panduan pengambilan gambar agar kualitas input lebih konsisten, misalnya jarak kamera, pencahayaan yang dianjurkan, posisi buah, serta larangan menggunakan citra yang terlalu buram. Pada versi berikutnya, model dapat dioptimalkan untuk edge device agar sebagian proses berlangsung tanpa koneksi internet. Pilihan antara cloud dan edge perlu mempertimbangkan akurasi, ukuran model, kecepatan, biaya perangkat, serta kemudahan pembaruan. Implementasi hibrida dapat digunakan dengan menjalankan klasifikasi awal pada perangkat dan mengirim citra ke server ketika dibutuhkan analisis lebih rinci atau pembaruan model.

3.12 Keterbatasan Penelitian dan Arah Pengembangan

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan ketika menafsirkan hasil. Pertama, dataset berjumlah 677 citra dan berasal dari kombinasi data primer serta repositori publik. Kombinasi tersebut memperluas jumlah sampel, tetapi juga dapat menimbulkan perbedaan karakteristik kamera, resolusi, pencahayaan, latar belakang, dan proses pelabelan. Model dapat mempelajari pola yang berkaitan dengan sumber citra apabila distribusi sumber tidak seimbang pada setiap kelas. Stratified random sampling menjaga proporsi kelas, tetapi belum tentu menjaga proporsi sumber data atau kondisi visual. Penelitian selanjutnya perlu mencatat metadata sumber, perangkat, waktu pengambilan, dan kondisi cahaya, kemudian memastikan pembagian data dilakukan secara berkelompok agar citra yang sangat mirip tidak tersebar pada data latih dan evaluasi.

Kedua, definisi keluaran hanya terdiri atas dua kelas, yaitu “Dapat Dipetik” dan “Tidak Dapat Dipetik”. Keluaran biner sesuai dengan kebutuhan keputusan operasional, tetapi menyederhanakan variasi biologis buah. Buah mentah, setengah matang, terlalu matang, dan busuk dapat membutuhkan penanganan yang berbeda. Model multi-kelas akan memberikan informasi lebih rinci, sedangkan antarmuka tetap dapat menyederhanakan hasil menjadi rekomendasi panen. Penambahan kelas juga memungkinkan analisis kesalahan yang lebih spesifik dan membantu menentukan tahap kematangan yang paling sulit dibedakan. Penelitian klasifikasi kematangan berbasis citra menunjukkan bahwa perbedaan tahap sering kali bersifat gradual dan dipengaruhi oleh warna, tekstur, serta kondisi lingkungan (Hamaguti & Breve, 2025; Wan Hamri & Jabbar, 2024).

Ketiga, evaluasi model masih berfokus pada metrik klasifikasi dan pengujian fungsional aplikasi. Belum terdapat validasi eksternal pada kebun lain, pengujian prospektif oleh petani, evaluasi ketahanan terhadap perubahan musim, atau pengukuran dampak sistem terhadap ketepatan waktu panen. Akurasi pada subset pengujian belum tentu sama dengan akurasi ketika model menerima citra baru dari perangkat dan lingkungan yang berbeda. Penelitian lanjutan perlu melibatkan pengguna lapangan untuk menilai kemudahan penggunaan, tingkat kepercayaan, waktu pengambilan keputusan, dan jenis kesalahan yang dianggap paling merugikan. Uji lapangan juga dapat mengungkap kebutuhan antarmuka yang tidak terlihat pada pengujian black box, misalnya ukuran teks, petunjuk pengambilan citra, bahasa, dan mekanisme penyimpanan riwayat hasil.

Keempat, penelitian belum membandingkan waktu inferensi dan penggunaan sumber daya dengan arsitektur alternatif. EfficientNet-B0 relatif ringan, tetapi klaim efisiensi akan lebih kuat apabila dilengkapi jumlah parameter, ukuran berkas model, penggunaan memori, dan waktu prediksi pada CPU serta perangkat seluler. Pengukuran ini penting untuk menentukan kelayakan implementasi edge. Selain itu, pemantauan model setelah deployment diperlukan untuk mendeteksi model drift, yaitu perubahan performa akibat kondisi data baru. Mekanisme pengumpulan umpan balik dapat ditambahkan agar pengguna menandai prediksi yang keliru, kemudian data tersebut ditinjau dan digunakan pada proses pembaruan model. Pembaruan harus dilakukan melalui prosedur validasi yang terdokumentasi agar peningkatan pada data baru tidak menurunkan performa pada kondisi lama.

Secara keseluruhan, arah pengembangan yang paling penting adalah memperbesar dan menyeimbangkan dataset lapangan, memperinci kelas kematangan, melakukan validasi eksternal, serta mengukur performa sistem secara menyeluruh. Grad-CAM dapat dipertahankan sebagai komponen transparansi, tetapi perlu dilengkapi evaluasi kuantitatif terhadap kualitas penjelasan. Sistem web dapat dikembangkan menuju arsitektur yang mendukung autentikasi, pencatatan prediksi, pemantauan versi model, dan pengumpulan data umpan balik. Pengembangan deteksi real-time dan implementasi pada perangkat edge sebagaimana disarankan pada kesimpulan akan memperluas penerapan, terutama apabila konektivitas internet terbatas. Dengan memenuhi tahapan tersebut, sistem dapat bergerak dari prototipe penelitian menuju alat bantu smart farming yang lebih andal, terukur, dan sesuai dengan kebutuhan pengguna.

3.13 Sintesis Kontribusi Penelitian

Kontribusi penelitian ini dapat dilihat pada tiga tingkat. Pada tingkat metodologis, penelitian tidak hanya menerapkan transfer learning menggunakan EfficientNet-B0, tetapi juga membandingkan tiga skenario pembagian data dan memilih konfigurasi berdasarkan stabilitas proses pembelajaran. Temuan bahwa rasio 80:10:10 lebih meyakinkan daripada dua rasio yang menghasilkan akurasi sempurna pada epoch pertama menunjukkan pentingnya membaca pola konvergensi dan karakteristik subset, bukan hanya memilih nilai metrik tertinggi. Penelitian juga mengevaluasi pengaruh augmentasi dan menemukan bahwa transformasi yang agresif tidak meningkatkan performa pada dataset ini. Hasil tersebut menegaskan bahwa augmentasi harus disesuaikan dengan fitur visual objek, karena perubahan yang terlalu kuat dapat menghilangkan informasi halus yang berkaitan dengan tekstur dan pigmentasi stroberi (Shorten & Khoshgoftaar, 2019).

Pada tingkat interpretabilitas, integrasi Grad-CAM dan OpenCV memberikan bukti visual bahwa model berfokus pada area buah yang relevan. Fokus pada pigmentasi merah untuk kelas “Dapat Dipetik” dan area putih kehijauan untuk kelas “Tidak Dapat Dipetik” memperkuat hubungan antara keputusan model dan indikator fisik kematangan. Penjelasan visual ini menjadi pembeda utama dari sistem yang hanya menampilkan label akhir. Dengan tetap mengakui keterbatasan Grad-CAM sebagai metode post hoc, penelitian telah menunjukkan bagaimana explainable AI dapat dimasukkan ke dalam alur aplikasi, bukan hanya digunakan pada tahap analisis laboratorium. Pengguna dapat membandingkan citra asli, heatmap, dan overlay dalam satu antarmuka, sehingga hasil prediksi lebih mudah diperiksa secara kritis.

Pada tingkat implementasi, penelitian berhasil mengintegrasikan model, API, pemrosesan visual, kontainerisasi, dan antarmuka responsif dalam layanan berbasis web. Integrasi tersebut menunjukkan bahwa keluaran penelitian deep learning dapat diterjemahkan menjadi prototipe yang dapat diakses oleh pengguna tanpa perangkat keras khusus. Nilai praktisnya tidak hanya terletak pada akurasi 97,79%, tetapi juga pada kemampuan sistem menyediakan hasil yang dapat dijelaskan dan ditampilkan melalui perangkat seluler. Meskipun masih memerlukan validasi lapangan, pengukuran performa server, dan perluasan dataset, rancangan ini membentuk dasar yang jelas bagi pengembangan alat bantu panen. Dengan demikian, kontribusi utama penelitian bukan semata-mata model klasifikasi, melainkan kerangka terintegrasi yang menghubungkan akurasi, transparansi, dan aksesibilitas untuk mendukung penerapan kecerdasan buatan pada sektor pertanian.

4. Kesimpulan

Penerapan Transfer Learning menggunakan arsitektur EfficientNet-B0 terbukti efektif untuk mengklasifikasikan tingkat kematangan buah stroberi, dengan model mencapai akurasi validasi akhir sebesar 97,79% dan presisi pada kelas matang mencapai 98,46%, yang menunjukkan bahwa model mampu membedakan stroberi layak petik dan tidak layak petik dengan tingkat kesalahan yang sangat minim. Implementasi Explainable AI berbasis Grad-CAM yang dipadukan dengan OpenCV berhasil memberikan transparansi visual pada proses pengambilan keputusan model, dengan visualisasi heatmap yang membuktikan bahwa model berfokus secara akurat pada tekstur dan pigmen warna merah daging buah tanpa terdistraksi oleh latar belakang, sehingga meningkatkan kepercayaan pengguna terhadap hasil klasifikasi sistem. Sistem klasifikasi ini juga telah berhasil dibangun dan disebarkan dalam bentuk aplikasi web berbasis arsitektur microservices menggunakan Docker dan FastAPI, yang terbukti tangguh dalam mengatasi kendala kompatibilitas dependensi OpenCV pada lingkungan server cloud sehingga dapat diakses secara publik dan tetap responsif terhadap input pengguna. Penelitian lanjutan disarankan untuk memperkaya variasi dataset pada kondisi pencahayaan yang lebih ekstrem, menambahkan kelas kematangan transisi, serta mengarahkan pengembangan pada deteksi real-time dan implementasi pada perangkat edge guna mendukung penerapan smart farming secara lebih luas.

Referensi

1. Afrin, S., Gasparini, M., Forbes-Hernandez, T. Y., Reboredo-Rodriguez, P., Mezzetti, B., Varela-Lopez, A., Giampieri, F., & Battino, M. (2016). Promising health benefits of the strawberry: A focus on clinical studies. *Journal of Agricultural and Food Chemistry*, 64(22), 4435–4449. <https://doi.org/10.1021/acs.jafc.6b00857>
2. Bradski, G. (2000). The OpenCV library. *Dr. Dobb's Journal of Software Tools*.
3. Chai, J. J. K., Xu, J.-L., & O'Sullivan, C. (2023). Real-time detection of strawberry ripeness using augmented reality and deep learning. *Sensors*, 23(17), 7639. <https://doi.org/10.3390/s23177639>
4. Hamaguti, É. K., & Breve, F. A. (2025). Classification of strawberry maturity level from images using supervised classifiers and convolutional neural networks as feature extractors. In *Computational Science and Its Applications – ICCSA 2025* (pp. 327–335). Springer. https://doi.org/10.1007/978-3-031-96962-1_22
5. Hapsari, E. S., Tajidan, & Muktasam. (2025). Social, economic, and environmental factors in determining the sustainability of tourist attractions: The case of strawberry agro-tourism in Sembalun District, Indonesia. *Asian Journal of Agriculture and Horticultural Research*, 12(3), 13–26.
6. Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 7132–7141). <https://doi.org/10.1109/CVPR.2018.00745>
7. Mi, Z., & Yan, W. Q. (2024). Strawberry ripeness detection using deep learning models. *Big Data and Cognitive Computing*, 8(8), 92. <https://doi.org/10.3390/bdcc8080092>
8. Park, J., Shin, J., Kim, R., et al. (2024). Accelerating strawberry ripeness classification using a convolution-based feature extractor along with an edge AI processor. *Electronics*, 13(2), 344. <https://doi.org/10.3390/electronics13020344>
9. Ramachandran, P., Zoph, B., & Le, Q. V. (2018). Searching for activation functions. *arXiv*. <https://doi.org/10.48550/arXiv.1710.05941>
10. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). <https://doi.org/10.1109/CVPR.2018.00474>
11. Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 618–626). <https://doi.org/10.1109/ICCV.2017.74>
12. Setiawan, I., Tridakusumah, A. C., Heryanto, M. A., et al. (2026). Socio-economic factors influencing strawberry farming development in West Java, Indonesia. *BIO Web of Conferences*, 225, 07005.
13. Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
14. Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning* (pp. 6105–6114).
15. von Eschenbach, W. J. (2021). Transparency and the black box problem: Why we do not trust AI. *Philosophy & Technology*, 34(4), 1607–1622. <https://doi.org/10.1007/s13347-021-00477-0>
16. Wan Hamri, W. M. S., & Jabbar, M. H. (2024). Classification of strawberry ripeness stages using deep learning. *Evolution in Electrical and Electronic Engineering*, 5(2), 74–81. <https://doi.org/10.30880/eeee.2024.05.02.009>
17. Yang, B., & Xu, Y. (2021). Applications of deep-learning approaches in horticultural research: A review. *Horticulture Research*, 8, 123. <https://doi.org/10.1038/s41438-021-00560-9>

DOI: <https://doi.org/10.31004/riggs.v5i2.12873>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)