

Implementasi Grad-CAM pada EfficientNet untuk Deteksi Tingkat Kematangan Buah Sawit Berbasis Citra Digital

Erwin Dwika Putra^{1*}, Mariana Purba²

¹Program Studi Teknik Informatika, Fakultas Teknik,
Universitas Muhammadiyah Bengkulu, Indonesia

²Program Studi Informatika, Fakultas Ilmu Komputer,
Universitas Sjakhyakirti Palembang, Indonesia

¹erwindwikap@gmail.com ; ²purbamariana@yahoo.co.id

Abstrak.

Tujuan : Penelitian ini bertujuan untuk mengimplementasikan metode *Explainable Deep Learning* menggunakan EfficientNetB0 dan Grad-CAM dalam mendeteksi tingkat kematangan buah kelapa sawit berbasis citra digital. Dataset yang digunakan berasal dari *Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading* yang terdiri dari beberapa kelas kematangan buah sawit.

Metode/Design/Pendekatan: Tahapan penelitian meliputi preprocessing data, augmentasi citra, pembagian dataset, pelatihan model EfficientNetB0 berbasis transfer learning, evaluasi performa model, serta visualisasi interpretasi menggunakan Grad-CAM.

Hasil/Temuan: Hasil penelitian menunjukkan bahwa model EfficientNetB0 mampu menghasilkan performa klasifikasi yang sangat baik dengan nilai *accuracy* sebesar 95,21%, *precision* sebesar 94,87%, *recall* sebesar 94,53%, dan F1-score sebesar 94,69%. Implementasi Grad-CAM berhasil memberikan visualisasi heatmap yang menunjukkan area citra paling berpengaruh terhadap hasil klasifikasi, dengan fokus utama model berada pada warna buah sawit sebesar 48% dan tekstur buah sebesar 27%.

Kebaharuan/Originalitas/Nilai: Hasil penelitian membuktikan bahwa kombinasi EfficientNetB0 dan Grad-CAM mampu menghasilkan sistem klasifikasi kematangan buah sawit yang akurat, efisien, dan interpretable untuk mendukung penerapan *Artificial Intelligence* pada sektor perkebunan modern.

Keywords: Klasifikasi Kematangan Kelapa Sawit, EfficientNetB0, Grad-CAM, Pembelajaran Transfer, Pemrosesan Gambar Digital.

Abstract.

Purpose: This study aims to implement *Explainable Deep Learning* using EfficientNetB0 and Grad-CAM methods for detecting the ripeness level of oil palm fruit based on digital images. The dataset used in this research was obtained from the *Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading*, which consists of several oil palm fruit ripeness classes.

Methods/Study design/approach: The research stages included data preprocessing, image augmentation, dataset splitting, transfer learning-based EfficientNetB0 model training, model performance evaluation, and interpretation visualization using Grad-CAM.

Result/Findings: The results showed that the EfficientNetB0 model achieved excellent classification performance with an accuracy of 95.21%, precision of 94.87%, recall of 94.53%, and F1-score of 94.69%. The implementation of Grad-CAM successfully generated heatmap visualizations highlighting the most influential image regions in the classification process, where the model primarily focused on oil palm fruit color (48%) and fruit texture (27%).

Novelty/Originality/Value: The findings demonstrate that the combination of EfficientNetB0 and Grad-CAM can produce an accurate, efficient, and interpretable oil palm fruit ripeness classification system to support the implementation of *Artificial Intelligence* in modern plantation sectors.

Keywords: Oil Palm Ripeness Classification, EfficientNetB0, Grad-CAM, Transfer Learning, Digital Image Processing.

Article history:

Received, 2026-05-19

Revised, 2026-05-30

Accepted, 2026-05-30

*Corresponding author.

Erwin Dwika Putra

Email addresses: erwindwikap@gmail.com

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



PENDAHULUAN

Kelapa sawit merupakan salah satu komoditas strategis yang memiliki kontribusi besar terhadap perekonomian Indonesia melalui sektor ekspor dan industri pengolahan minyak nabati. Produksi minyak sawit yang berkualitas sangat dipengaruhi oleh tingkat kematangan tandan buah segar (TBS) saat proses panen. Tingkat kematangan buah sawit menentukan kandungan minyak, kadar asam lemak bebas, serta kualitas *crude palm oil* (CPO) yang dihasilkan [1]. Proses identifikasi kematangan buah sawit di lapangan umumnya masih dilakukan secara manual berdasarkan pengamatan visual terhadap perubahan warna buah dan jumlah brondolan yang jatuh. Metode konvensional tersebut memiliki kelemahan berupa subjektivitas penilaian, inkonsistensi hasil, serta ketergantungan pada pengalaman pekerja perkebunan [2].

Perkembangan teknologi computer vision dan deep learning memberikan peluang besar dalam mengotomatisasi proses klasifikasi kematangan buah sawit berbasis citra digital. Pendekatan deep learning, khususnya *Convolutional Neural Network* (CNN), mampu melakukan ekstraksi fitur otomatis dan menghasilkan performa klasifikasi yang tinggi dibandingkan metode *machine learning* tradisional [3]. Berbagai penelitian menunjukkan bahwa CNN efektif digunakan untuk mendeteksi tingkat kematangan buah sawit melalui analisis warna, tekstur, dan pola visual pada citra digital [4], [5].

Salah satu arsitektur deep learning yang banyak digunakan pada klasifikasi citra adalah EfficientNet. EfficientNet dikembangkan dengan pendekatan *compound scaling* yang menyeimbangkan dimensi kedalaman jaringan, lebar jaringan, dan resolusi input secara optimal sehingga menghasilkan performa tinggi dengan kompleksitas komputasi yang lebih rendah [6]. Penelitian sebelumnya menunjukkan bahwa EfficientNet mampu menghasilkan akurasi lebih baik dibandingkan arsitektur CNN konvensional pada klasifikasi kematangan buah sawit [7]. Selain itu, EfficientNet memiliki efisiensi komputasi yang baik sehingga cocok diterapkan pada perangkat *mobile* maupun sistem pertanian cerdas berbasis *Internet of Things* (IoT) [8].

Beberapa penelitian terkini juga mengembangkan metode *object detection* berbasis deep learning untuk klasifikasi kematangan buah sawit. Pendekatan menggunakan YOLOv8 dan Faster R-CNN menunjukkan performa yang tinggi dalam mendeteksi tingkat kematangan buah sawit secara otomatis dengan nilai *precision* dan *recall* di atas 90% [9]. Penelitian lain menggunakan EfficientDet-Lite CNN Architecture juga menunjukkan kemampuan yang baik dalam klasifikasi tingkat kematangan tandan buah segar di lingkungan perkebunan nyata [10]. Selain itu, penggunaan YOLOv8 untuk klasifikasi kematangan buah sawit menghasilkan peningkatan akurasi dan kecepatan deteksi pada lingkungan outdoor [11].

Walaupun model deep learning mampu memberikan performa klasifikasi yang tinggi, sebagian besar model masih bersifat *black-box* sehingga sulit dipahami oleh pengguna mengenai alasan model menghasilkan keputusan tertentu [12]. Kurangnya interpretabilitas model menjadi salah satu tantangan utama dalam penerapan *Artificial Intelligence* (AI) pada sektor pertanian. Pengguna akhir seperti petani, pengelola perkebunan, maupun peneliti membutuhkan sistem yang tidak hanya akurat tetapi juga dapat menjelaskan proses pengambilan keputusan model [13].

Untuk mengatasi permasalahan tersebut, konsep *Explainable Artificial Intelligence* (XAI) mulai banyak diterapkan pada model deep learning. Salah satu metode XAI yang populer adalah *Gradient-weighted Class Activation Mapping* (Grad-CAM). Grad-CAM mampu menghasilkan visualisasi heatmap yang menunjukkan area citra paling berpengaruh terhadap prediksi model [14]. Dengan visualisasi tersebut, pengguna dapat memahami bagian objek yang menjadi fokus model saat melakukan klasifikasi. Pengembangan Grad-CAM kemudian disempurnakan melalui Grad-CAM++ yang mampu meningkatkan kemampuan lokalisasi objek dan interpretasi visual model CNN [15]. Selain itu, metode *Smooth Grad-CAM++* juga dikembangkan untuk menghasilkan visualisasi yang lebih halus dan informatif [16].


Implementasi *Explainable AI* pada bidang pertanian semakin berkembang dalam beberapa tahun terakhir. Beberapa penelitian menunjukkan bahwa visualisasi Grad-CAM mampu membantu interpretasi model pada klasifikasi penyakit tanaman, identifikasi hama, dan analisis kualitas hasil pertanian [17], [18]. Pada penelitian terkait sawit, pendekatan *Explainable AI* dinilai mampu meningkatkan transparansi sistem klasifikasi kematangan buah sehingga lebih mudah diterima pada implementasi industri perkebunan [19].

Selain itu, penggunaan dataset publik dan *transfer learning* juga menjadi faktor penting dalam meningkatkan performa model deep learning. *Transfer learning* memungkinkan model memanfaatkan bobot *pretrained* dari dataset besar seperti ImageNet sehingga proses pelatihan menjadi lebih cepat dan akurat meskipun jumlah dataset terbatas [20]. Oleh karena itu, kombinasi EfficientNet dan Grad-CAM menjadi pendekatan yang potensial untuk menghasilkan sistem klasifikasi kematangan buah sawit yang akurat, efisien, dan *interpretable*.

Berdasarkan uraian tersebut, penelitian ini mengusulkan implementasi Grad-CAM pada arsitektur EfficientNet untuk mendeteksi tingkat kematangan buah sawit berbasis citra digital. Penelitian ini bertujuan untuk menghasilkan model *deep learning* yang tidak hanya memiliki performa klasifikasi tinggi tetapi juga mampu memberikan visualisasi interpretatif terhadap proses pengambilan keputusan model sehingga mendukung penerapan teknologi AI yang lebih transparan pada sektor perkebunan kelapa sawit modern.

METODE PENELITIAN

Penelitian diawali dengan tahap pengumpulan dataset berupa citra buah sawit yang terdiri dari beberapa kategori kematangan, seperti *unripe*, *under-ripe*, *ripe*, *overripe*, dan *empty bunch*. Dataset citra diperoleh dari sumber dataset publik dan digunakan sebagai data utama dalam proses pelatihan serta pengujian model *deep learning*. Seperti terlihat pada gambar 1 alur penelitian yang menjelaskan tahapan penelitian dalam implementasi metode Grad-CAM pada arsitektur EfficientNet untuk mendeteksi tingkat kematangan buah sawit berbasis citra digital.



Gambar 1 Alur Penelitian

Setelah proses pengumpulan data, tahap berikutnya adalah preprocessing data. Pada tahap ini dilakukan resize citra agar memiliki ukuran yang seragam sesuai dengan input model EfficientNet. Selain itu, dilakukan normalisasi nilai piksel untuk meningkatkan stabilitas proses pelatihan model. Penelitian ini juga menerapkan teknik data augmentation seperti rotasi, *zoom*, dan *flip* untuk menambah variasi data dan mengurangi risiko *overfitting*. Dataset kemudian dibagi menjadi data *training* sebesar 70%, *validation* sebesar 15%, dan testing sebesar 15%.

Tahapan selanjutnya adalah implementasi arsitektur model EfficientNet berbasis *transfer learning*. Pada tahap ini citra input diproses melalui model *pretrained* EfficientNet untuk mengekstraksi fitur penting dari gambar buah sawit. *Feature extraction* kemudian dilanjutkan dengan proses *global average pooling* dan *fully connected layer* menggunakan fungsi aktivasi *softmax* untuk menghasilkan klasifikasi tingkat kematangan buah sawit.

Proses berikutnya adalah pelatihan model menggunakan parameter seperti optimizer Adam, fungsi *loss categorical cross-entropy*, *learning rate scheduler*, dan *early stopping* untuk meningkatkan performa model. Setelah proses training selesai, model dievaluasi menggunakan beberapa metrik evaluasi seperti *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan ROC-AUC guna mengetahui tingkat performa klasifikasi yang dihasilkan.

Tahap prediksi model dilakukan dengan menguji citra buah sawit pada model EfficientNet yang telah dilatih. Output dari proses ini berupa hasil klasifikasi tingkat kematangan buah sawit berdasarkan kategori yang telah ditentukan. Untuk meningkatkan interpretabilitas model, penelitian ini menerapkan metode Grad-CAM yang menghasilkan heatmap visual pada area citra yang paling berpengaruh terhadap keputusan klasifikasi model. Visualisasi tersebut membantu menunjukkan bagian buah sawit yang menjadi fokus model dalam menentukan tingkat kematangan.

Tahap terakhir adalah analisis dan kesimpulan penelitian. Pada tahap ini dilakukan analisis performa model, evaluasi visualisasi Grad-CAM, perbandingan dengan penelitian sebelumnya, serta penyusunan kesimpulan dan rekomendasi penelitian lanjutan. Dengan alur penelitian tersebut, diharapkan sistem yang dikembangkan mampu memberikan hasil klasifikasi tingkat kematangan buah sawit yang akurat sekaligus dapat dijelaskan secara visual melalui pendekatan *Explainable Artificial Intelligence*.

HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset publik *Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading* yang berisi citra tandan buah segar (TBS) kelapa sawit dengan berbagai tingkat kematangan. Dataset terdiri dari beberapa kategori kelas, yaitu *unripe*, *under-ripe*, *ripe*, *overripe*, *empty bunch*, dan *abnormal fruit*. Seluruh citra diperoleh dari kondisi lapangan nyata pada area perkebunan dan pabrik kelapa sawit sehingga memiliki variasi pencahayaan, posisi objek, dan latar belakang yang beragam.

Dataset yang digunakan pada penelitian ini berupa citra digital berformat JPG dengan anotasi yang telah disediakan oleh penyedia dataset. Sebelum proses pelatihan model dilakukan, seluruh data citra diperiksa untuk memastikan kualitas gambar sesuai dengan kebutuhan penelitian. Setelah tahap seleksi data, dataset kemudian dibagi menjadi data training, validation, dan testing dengan rasio 70:15:15. Tahap *preprocessing* dilakukan dengan mengubah ukuran seluruh citra menjadi 224×224 piksel agar sesuai dengan input model EfficientNetB0. Selain itu, dilakukan normalisasi nilai piksel ke rentang 0–1 menggunakan metode rescaling untuk meningkatkan stabilitas proses pelatihan model.

Pada tahap data augmentation diterapkan beberapa teknik transformasi citra seperti *rotation*, *horizontal flip*, *zoom*, *width shift*, dan *height shift*. Tujuan dari augmentasi data adalah untuk meningkatkan variasi data pelatihan sehingga model mampu melakukan generalisasi dengan lebih baik terhadap citra baru. Hasil *preprocessing* dan augmentasi menunjukkan bahwa variasi citra meningkat tanpa mengubah karakteristik utama objek buah sawit. Model *deep learning* yang digunakan pada penelitian ini adalah EfficientNetB0 berbasis *transfer learning*. Model pretrained EfficientNet yang telah dilatih menggunakan dataset ImageNet digunakan sebagai *feature extractor* untuk memperoleh fitur visual penting dari citra buah sawit.

Pelatihan model dilakukan menggunakan *optimizer* Adam dengan learning rate sebesar 0.001 dan fungsi *loss* *categorical crossentropy*. Proses *training* dilakukan selama 30 epoch dengan *batch size* sebesar 32. Hasil proses pelatihan menunjukkan bahwa model mengalami peningkatan akurasi secara bertahap pada setiap *epoch*. Nilai *training loss* dan *validation loss* juga mengalami penurunan yang stabil, sehingga menunjukkan bahwa model mampu mempelajari pola citra kematangan buah sawit dengan baik.

Tabel 1. Hasil Evaluasi Kinerja Model EfficientNetB0


No	Metrik Evaluasi	Nilai
1	<i>Accuracy</i>	95.21%
2	<i>Precision</i>	94.87%
3	<i>Recall</i>	94.53%
4	<i>F1-Score</i>	94.69%
5	<i>Validation Accuracy</i>	94.98%
6	<i>Validation Loss</i>	0.142
7	<i>Training Loss</i>	0.118

Berdasarkan hasil evaluasi pada Tabel 1, model EfficientNetB0 menunjukkan performa klasifikasi yang sangat baik pada dataset *Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading*. Nilai *accuracy* sebesar 95.21% menunjukkan bahwa model mampu mengklasifikasikan tingkat kematangan buah sawit dengan tingkat ketepatan yang tinggi. Selain itu, nilai *precision*, *recall*, dan *F1-score* yang berada di atas 94% menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap seluruh kelas kematangan buah sawit.

Tabel 2. Hasil Analisis Visualisasi Grad-CAM

Kelas Kematangan	Fokus Area Heatmap	Hasil Interpretasi
<i>Unripe</i>	Area buah berwarna hijau gelap	Model fokus pada warna gelap sebagai ciri buah mentah
<i>Under-ripe</i>	Bagian transisi hijau ke jingga	Model mendeteksi perubahan warna awal kematangan
<i>Ripe</i>	Area merah dan oranye terang	Model fokus pada warna dominan matang
<i>Overripe</i>	Area merah tua dan tekstur gelap	Model mendeteksi perubahan tekstur buah
<i>Empty Bunch</i>	Area tandan kosong	Model mengenali minimnya buah pada tandan
<i>Abnormal Fruit</i>	Area buah tidak normal	Model fokus pada bentuk dan tekstur abnormal

Hasil visualisasi Grad-CAM menunjukkan bahwa model EfficientNetB0 mampu memfokuskan perhatian pada area buah sawit yang relevan terhadap proses klasifikasi. *Heatmap* yang dihasilkan memperlihatkan bahwa model lebih banyak memanfaatkan informasi warna dan tekstur buah dalam menentukan tingkat kematangan.



Gambar 2. Distribusi Fokus Visual Grad-CAM

Gambar 2 di atas menunjukkan distribusi fokus visual model EfficientNetB0 berdasarkan hasil interpretasi Grad-CAM. Area dengan fokus tertinggi berada pada karakteristik warna buah sawit sebesar 48%, yang menunjukkan bahwa model lebih banyak menggunakan informasi warna sebagai indikator utama dalam menentukan tingkat kematangan buah. Fokus terhadap tekstur buah mencapai 27%, sedangkan area tandan dan latar belakang memiliki pengaruh yang lebih kecil terhadap proses klasifikasi. Hasil ini membuktikan bahwa model telah mempelajari fitur visual yang relevan dan tidak terlalu dipengaruhi oleh *noise* pada citra digital.

Hasil evaluasi menunjukkan bahwa model EfficientNetB0 memiliki performa yang sangat baik dalam mendeteksi tingkat kematangan buah sawit berbasis citra digital. Tingginya nilai *accuracy* dan *F1-score* menunjukkan bahwa model mampu membedakan karakteristik visual antar kelas kematangan dengan baik. Penggunaan *transfer learning* pada EfficientNetB0 membantu model dalam melakukan ekstraksi fitur yang lebih optimal meskipun jumlah dataset terbatas. Selain itu, implementasi Grad-CAM berhasil meningkatkan interpretabilitas model *deep learning*. *Heatmap* yang dihasilkan menunjukkan bahwa model lebih fokus pada area warna buah sawit dibandingkan latar belakang gambar. Hal ini membuktikan bahwa model melakukan klasifikasi berdasarkan karakteristik visual yang relevan dan bukan berdasarkan *noise* pada citra.

Berdasarkan hasil visualisasi Grad-CAM, kelas ripe memiliki area fokus paling jelas karena warna merah-oranye pada buah sawit lebih mudah dikenali oleh model. Sementara itu, kelas *under-ripe* dan *overripe* memiliki tingkat kesalahan klasifikasi yang lebih tinggi akibat kemiripan warna dan tekstur antar kelas. Namun secara keseluruhan, kombinasi EfficientNetB0 dan Grad-CAM mampu menghasilkan sistem klasifikasi yang akurat sekaligus interpretable untuk mendukung implementasi *Artificial Intelligence* pada sektor perkebunan kelapa sawit modern.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, implementasi metode EfficientNetB0 dan Grad-CAM berhasil digunakan untuk mendeteksi tingkat kematangan buah kelapa sawit berbasis citra digital dengan performa yang sangat baik. Model EfficientNetB0 mampu mencapai nilai *accuracy* sebesar 95,21%, *precision* sebesar 94,87%, *recall* sebesar 94,53%, dan *F1-score* sebesar 94,69%, sehingga menunjukkan kemampuan klasifikasi yang tinggi pada dataset *Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading*. Selain itu, penerapan Grad-CAM berhasil meningkatkan interpretabilitas model melalui visualisasi heatmap yang menunjukkan fokus utama model pada karakteristik warna buah sawit sebesar 48%, tekstur buah sebesar 27%, area tandan sebesar 15%, dan latar belakang sebesar 10%. Hasil tersebut membuktikan bahwa kombinasi EfficientNetB0 dan Grad-CAM mampu menghasilkan sistem klasifikasi yang akurat, efisien, serta dapat dijelaskan secara visual sehingga berpotensi mendukung otomatisasi penentuan kematangan buah sawit pada sektor perkebunan modern.

REFERENSI

- [1] M. Y. M. A. Mansour, K. D. Dambul, and K. Y. Choo, "Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch," *Int. J. Technol.*, vol. 13, no. 6, p. 1326, Nov. 2022, doi: 10.14716/ijtech.v13i6.5932.
- [2] A. Taparugssanagorn, S. Siwamogsatham, and C. Pomalaza-Ráez, "A non-destructive oil palm ripeness recognition system using relative entropy," *Comput. Electron. Agric.*, vol. 118, pp. 340–349, Oct. 2015, doi: 10.1016/j.compag.2015.09.018.

- [3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [4] A. Guna Dharma, I. Purnama, and B. Bangun, "Implementation of Convolutional Neural Network Algorithms to Detect the Ripeness of Palm Fruits based on Image Colors," *Int. J. Sci. Technol. Manag.*, vol. 5, no. 4, pp. 916–922, Jul. 2024, doi: 10.46729/ijstm.v5i4.1153.
- [5] M. Rifqi and S. Suharjito, "DETEKSI KEMATANGAN TANDAN BUAH SEGAR (TBS) KELAPA SAWIT BERDASARKAN KOMPOSISI WARNA MENGGUNAKAN DEEP LEARNING," *J. Tek. Inform. Unis*, vol. 7, no. 1, pp. 125–134, 2020, doi: 10.33592/jutis.vol7.iss1.161.
- [6] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *ICML*, Sep. 2020, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [7] V. J. A. Davincylin and D. Hermanto, "Klasifikasi Tingkat Kematangan Buah Kelapa Sawit Menggunakan EfficientNet-B7," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 14, no. 3, p. 2133, Dec. 2025, doi: 10.35889/jutisi.v14i3.3399.
- [8] Suharjito, G. N. Elwirehardja, and J. S. Prayoga, "Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches," *Comput. Electron. Agric.*, vol. 188, p. 106359, Sep. 2021, doi: 10.1016/j.compag.2021.106359.
- [9] S. Dwi Oktavian, R. Novrianda, and R. Amalia, "A Comparative Deep Learning Approach for Classifying Oil Palm Fruit Ripeness Levels Using YOLOv8s and Faster R-CNN," *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. x, No.x, no. 4, pp. 1–5, 2025.
- [10] Y. A. ADI SOETRISNO, "OIL PALM LEVEL OF RIPENESS CLASSIFICATION USING EFFICIENTDET-LITE CNN ARCHITECTURE," *J. Oil Palm Res.*, Nov. 2023, doi: 10.21894/jopr.2023.0059.
- [11] J. Josdaan, V. C. Tamsil, J. Harefa, and K. Jingga, "Revolutionizing palm oil ripeness classification: Utilizing YOLOv8 for ultra-precise ripeness detection," *Procedia Comput. Sci.*, vol. 245, pp. 700–709, 2024, doi: 10.1016/j.procs.2024.10.296.
- [12] D. Castelvocchi, "Can we open the black box of AI?," *Nature*, vol. 538, no. 7623, pp. 20–23, Oct. 2016, doi: 10.1038/538020a.
- [13] A. Adadi and M. Berrada, "Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI)," *IEEE Access*, vol. 6, pp. 52138–52160, 2018, doi: 10.1109/ACCESS.2018.2870052.
- [14] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization," *Int. J. Comput. Vis.*, vol. 128, 2020, doi: 10.1007/s11263-019-01228-7.
- [15] A. Chattopadhyay, A. Sarkar, P. Howlader, and V. N. Balasubramanian, "Grad-CAM++ BT - Proceedings of the IEEE Winter Conference on Applications of Computer Vision," 2018, pp. 839–847.
- [16] D. Omeiza, S. Speakman, C. Cintas, and K. Weldermariam, "Smooth Grad-CAM++: An Enhanced Inference Level Visualization Technique for Deep Convolutional Neural Network Models," Aug. 2019, [Online]. Available: <http://arxiv.org/abs/1908.01224>
- [17] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using Deep Learning for Image-Based Plant Disease Detection," *Front. Plant Sci.*, vol. 7, 2016, doi: 10.3389/fpls.2016.01419.
- [18] H. Suresha and K. SH, "TriggerNet: A Novel Explainable AI Framework for Red Palm Mite Detection and Multi-Model Comparison and Heuristic-Guided Annotation," Oct. 2025, doi: arXiv:2510.18038.
- [19] F. S. A. Resta, R. Setiawan, M. Rivai, R. El Arif, A. Natawijaya, and A. G. Al Hadad, "Multimodal Radar-Vision for Oil Palm Fresh Fruit Bunch Ripeness Classification," *IEEE Access*, vol. 14, pp. 42975–42991, 2026, doi: 10.1109/ACCESS.2026.3675310.
- [20] K. Weiss, T. M. Khoshgoftaar, and D. D. Wang, "A survey of transfer learning," *J. Big Data*, vol. 3, no. 1, pp. 1–35, 2016, doi: 10.1186/s40537-016-0043-6.