

Perbandingan Kinerja MobileNetV2 dan ResNet50V2 Dalam Klasifikasi Tingkat Kematangan Tomat

Ravansa Rahman Santosa¹, Anindia Sasikirana², Zidan Lutfi Ramadhan³, Yusuf Putra Bintang Satria⁴,
Agung Nugroho⁵

^{1,2,3,4,5} Fakultas Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

Article Info

Article history:

Received Juni 22, 2025

Revised Juni 28, 2025

Accepted Juni 28, 2025

Kata Kunci:

MobileNetV2,
ResNet50V2,
Klasifikasi Citra,
CNN,
Tomat

Keywords:

MobileNetV2,
ResNet50V2,
Image Classification,
CNN,
Tomato

ABSTRAK

Perkembangan teknologi deep learning telah mendorong pemanfaatan arsitektur Convolutional Neural Network (CNN) dalam berbagai tugas klasifikasi citra. Di antara arsitektur yang populer, MobileNet dan ResNet memiliki karakteristik yang berbeda dalam hal efisiensi dan akurasi. Penelitian ini bertujuan untuk membandingkan performa dua arsitektur CNN, yaitu MobileNetV2 dan ResNet50V2, dalam mengklasifikasikan tingkat kematangan tomat ke dalam tiga kategori: mentah, setengah matang, dan matang. Dataset citra tomat digunakan dalam pelatihan dan pengujian model, dengan evaluasi berdasarkan metrik akurasi, presisi, recall, F1-score, serta waktu pengujian. Hasil penelitian menunjukkan bahwa MobileNetV2 unggul dalam efisiensi komputasi dengan akurasi sebesar 98,33% dan waktu pengujian lebih cepat, sedangkan ResNet50V2 mencapai akurasi 93,33% dengan kompleksitas model yang lebih tinggi. Berdasarkan hasil tersebut, MobileNetV2 direkomendasikan untuk implementasi pada perangkat dengan sumber daya terbatas, sementara ResNet50V2 lebih cocok untuk aplikasi dengan kebutuhan akurasi tinggi dan ketersediaan sumber daya yang memadai.

ABSTRACT

The advancement of deep learning technology has significantly influenced the application of Convolutional Neural Networks (CNNs) in various image classification tasks. Among the most widely adopted architectures, MobileNet and ResNet offer contrasting strengths in terms of efficiency and accuracy. This study aims to compare the performance of two CNN architectures, MobileNetV2 and ResNet50V2, in classifying the ripeness level of tomatoes into three categories: unripe, semi-ripe, and ripe. A custom tomato image dataset was used for training and testing, with performance evaluated based on accuracy, precision, recall, F1-score, and inference time. The results show that MobileNetV2 outperforms in computational efficiency, achieving an accuracy of 98.33% with faster inference time, while ResNet50V2 achieved 93.33% accuracy with higher model complexity. Based on these findings, MobileNetV2 is recommended for deployment on resource-constrained devices, whereas ResNet50V2 is more suitable for applications requiring high accuracy and sufficient computational resources.

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



Corresponding Author:

Ravansa Rahman Santosa
Fakultas Teknik Informatika, Universitas Pelita Bangsa
Bekasi, Indonesia
Email: ravansa04@mhs.pelitabangsa.ac.id

1. PENDAHULUAN

Perkembangan teknologi pengolahan citra digital telah mengalami kemajuan pesat dalam beberapa dekade terakhir. Salah satu pendorong utama kemajuan ini adalah penerapan metode deep learning, khususnya arsitektur Convolutional Neural Network (CNN), yang mampu melakukan ekstraksi fitur secara otomatis dan efisien dari data citra [1]. CNN telah menjadi algoritma mainstream dalam berbagai tugas visi komputer sejak tahun 2012 dan banyak diaplikasikan dalam berbagai bidang seperti deteksi objek, segmentasi citra, dan klasifikasi citra [2]. Salah satu implementasi penting dari pengolahan citra adalah klasifikasi citra, yaitu proses pengelompokan sejumlah pixel atau elemen gambar ke dalam kelas-kelas tertentu berdasarkan kemiripan fitur visual [3]. Proses ini memungkinkan komputer untuk menganalisis gambar dan mengenali objek atau kategori yang terkandung di dalamnya [4]. Namun demikian, klasifikasi citra masih memiliki tantangan, terutama karena terbatasnya proses feature engineering yang hanya berlaku pada dataset tertentu. Hal ini disebabkan oleh adanya variasi sudut pandang, skala, pencahayaan, dan deformasi objek pada setiap citra yang diolah [5]. Oleh karena itu, diperlukan pendekatan yang adaptif dan kuat seperti CNN yang dapat mengakomodasi kompleksitas data visual tersebut. CNN sendiri merupakan pengembangan dari Multi Layer Perceptron (MLP) dan menjadi bagian penting dari algoritma deep learning modern [6].

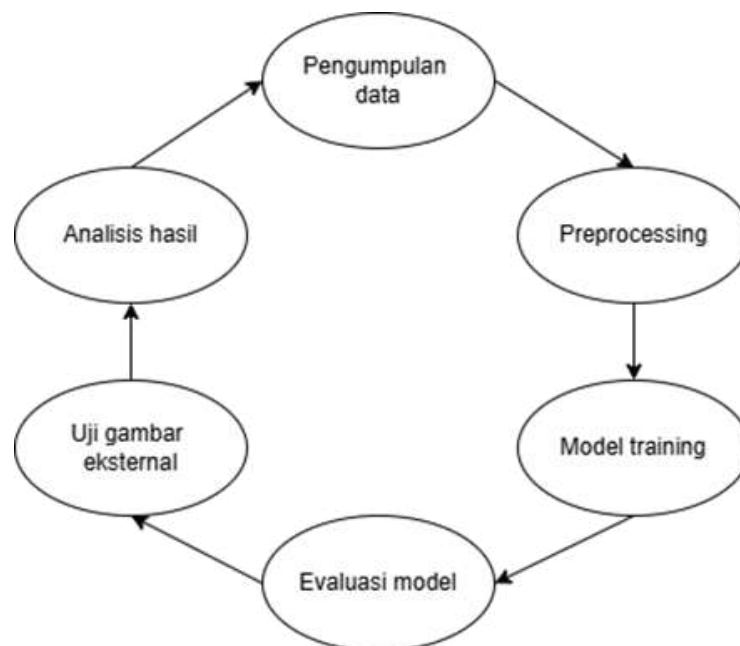
Di antara berbagai arsitektur CNN, dua model yang paling banyak digunakan dalam berbagai aplikasi adalah MobileNet dan ResNet. ResNet (Residual Network) merupakan jenis jaringan saraf yang diperkenalkan pada tahun 2015 oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun. ResNet menawarkan pendekatan arsitektural yang unik melalui penggunaan residual blocks, yang memungkinkan pelatihan jaringan sangat dalam tanpa mengalami degradasi performa. Dengan struktur tersebut, ResNet dapat terus meningkatkan akurasi seiring bertambahnya kedalaman jaringan, bahkan hingga ratusan lapisan. Model ini telah menunjukkan performa terbaik dalam kompetisi klasifikasi citra berskala besar seperti ImageNet, menjadikannya sangat sesuai untuk sistem dengan kapasitas komputasi tinggi dan kebutuhan akurasi maksimal [7], [8], [9]. Di sisi lain, MobileNet dikembangkan dengan fokus pada efisiensi komputasi dan latensi rendah, sehingga cocok untuk aplikasi pada perangkat mobile dan sistem tertanam. MobileNet menggunakan arsitektur streamlined berbasis depthwise separable convolutions, yang secara signifikan mengurangi kompleksitas perhitungan hingga 8–9 kali lebih rendah dibandingkan konvolusi standar, tanpa penurunan akurasi yang signifikan [10]. Model ini dirancang untuk memenuhi kebutuhan pengolahan citra yang cepat dan ringan, dengan dukungan dua set hyper-parameters yang memungkinkan penyesuaian berdasarkan keterbatasan sumber daya [11], [12].

Salah satu bidang aplikasi klasifikasi citra yang relevan dan bernilai tinggi dalam dunia nyata adalah penentuan tingkat kematangan buah, seperti tomat. Penentuan tingkat kematangan tomat sangat penting dalam industri pertanian, logistik, dan pemasaran, karena berpengaruh langsung terhadap kualitas, harga, dan masa simpan produk. Oleh karena itu, penelitian ini dilakukan untuk membandingkan performa dua arsitektur CNN populer, yaitu MobileNetV2 dan ResNet50V2, dalam tugas klasifikasi tingkat kematangan tomat yang terbagi ke dalam tiga kelas: mentah, setengah matang, dan matang [13]. Dengan menggunakan dataset citra tomat yang telah melalui proses pra-pemrosesan serta pembagian data secara sistematis, kedua model dilatih dan dievaluasi menggunakan metrik performa seperti akurasi, presisi, recall, dan F1-score. Penelitian ini bertujuan untuk mengkaji trade-off antara efisiensi dan akurasi dari masing-masing model, sehingga dapat memberikan rekomendasi

arsitektur CNN yang paling sesuai untuk diterapkan dalam sistem klasifikasi berbasis citra pada aplikasi dunia nyata yang memiliki keterbatasan sumber daya maupun kebutuhan akurasi tinggi.

2. METODE

Penelitian ini menggunakan pendekatan yang sistematis dan terstruktur untuk mengembangkan serta membandingkan performa dua model deep learning, yaitu MobileNetV2 dan ResNet50V2, dalam klasifikasi tingkat kematangan tomat. Diagram berikut menunjukkan alur metodologi yang diterapkan dalam penelitian ini.



Gambar 1. Alur proses penelitian dalam klasifikasi tingkat kematangan tomat menggunakan model MobileNetV2 dan ResNet50V2

Penelitian ini dilakukan melalui beberapa tahapan sistematis untuk membangun dan membandingkan performa dua arsitektur deep learning, yaitu MobileNetV2 dan ResNet50V2, dalam mengklasifikasikan tingkat kematangan tomat. Tahapan dimulai dengan merancang alur penelitian secara menyeluruh, kemudian dilanjutkan dengan pengumpulan data gambar tomat yang dikategorikan ke dalam tiga kelas, yaitu mentah, setengah matang, dan matang. Data yang telah dikumpulkan melalui proses pra-pemrosesan seperti resizing, normalisasi, dan pelabelan ulang agar siap digunakan untuk pelatihan. Selanjutnya, dataset dibagi menjadi data pelatihan, validasi, dan pengujian untuk memastikan proses evaluasi yang adil. Model MobileNetV2 dan ResNet50V2 kemudian dilatih menggunakan data pelatihan, dan performanya dievaluasi menggunakan data validasi serta pengujian berdasarkan metrik seperti akurasi, presisi, recall, dan F1-score. Setelah pelatihan dan evaluasi, model diuji menggunakan gambar eksternal yang tidak termasuk dalam dataset untuk melihat kemampuan generalisasi. Hasil dari evaluasi dan pengujian tersebut dianalisis untuk membandingkan performa kedua model secara komprehensif. Tahapan ini memastikan bahwa proses penelitian berjalan optimal dan dapat diulang jika diperlukan untuk perbaikan atau pengembangan lebih lanjut.

2.1 Pengumpulan Data

Dalam penelitian ini, data yang digunakan berasal dari sumber terbuka yang tersedia di platform Kaggle, yaitu dataset “Kematangan Buah Tomat” yang dibagikan oleh pengguna dengan nama kevinbagaskara [<https://www.kaggle.com/datasets/kevinbagaskara/kematangan-buah-tomat>]. Dataset

ini dipilih karena telah dikurasi dan dikelompokkan secara jelas berdasarkan tingkat kematangan buah tomat, yang sesuai dengan kebutuhan klasifikasi dalam penelitian ini.

Dataset tersebut terdiri dari kumpulan gambar tomat yang diklasifikasikan ke dalam tiga kategori utama, yaitu mentah, setengah matang, dan matang. Masing-masing gambar pada dataset mewakili variasi visual tomat berdasarkan warna, tekstur, dan tingkat pencahayaan yang realistis. Ketersediaan kategori yang seimbang dan representatif menjadi faktor penting dalam pemilihan dataset ini karena mendukung proses pelatihan model deep learning agar dapat melakukan klasifikasi secara optimal. Selain itu, data telah disusun ke dalam folder terpisah berdasarkan label kelas, yang memudahkan dalam proses pra-pemrosesan dan pelabelan otomatis saat pemodelan. Untuk menjaga kualitas data dan hasil pelatihan model, dilakukan pemeriksaan ulang terhadap kejelasan citra serta keberagaman dalam setiap kelas guna memastikan tidak ada citra duplikat, buram, atau tidak relevan.

2.2 Preprocessing

Pada tahap preprocessing, dilakukan proses augmentasi citra untuk meningkatkan jumlah dan keragaman data pelatihan. Dataset awal terdiri dari masing-masing 200 gambar tomat untuk kelas matang, setengah matang, dan mentah. Melalui teknik augmentasi seperti rotasi, flipping horizontal/vertikal, zoom, dan perubahan pencahayaan, jumlah gambar pada setiap kelas berhasil ditingkatkan menjadi 400 gambar per kelas. Augmentasi ini bertujuan untuk memperkaya variasi data, mengurangi risiko overfitting, serta meningkatkan kemampuan generalisasi model dalam mengenali berbagai kondisi visual tomat pada aplikasi nyata. Proses ini dilakukan secara proporsional agar distribusi antar kelas tetap seimbang dan hasil pelatihan model menjadi lebih optimal.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk membandingkan performa dua arsitektur deep learning populer, yaitu MobileNetV2 dan ResNet50V2, dalam melakukan klasifikasi kematangan tomat (Matang, Setengah Matang, dan Mentah). Evaluasi dilakukan berdasarkan akurasi, loss, waktu pengujian, serta metrik evaluasi lainnya seperti presisi, recall, dan F1-score.

3.1 Evaluasi Kinerja Model

Berdasarkan hasil pengujian model pada data uji, MobileNetV2 menunjukkan performa yang lebih unggul dibandingkan ResNet50V2. Tabel berikut merangkum hasil evaluasi kedua model.

Tabel 1. Perbandingan akurasi, nilai loss, dan waktu pengujian model MobileNetV2 dan ResNet50V2.

| Model | Akurasi | loss |
|-------------|---------|------|
| Mobilenetv2 | 0.98 | 0.05 |
| Resnet50v2 | 0.93 | 0.14 |

MobileNetV2 mencatatkan akurasi sebesar 98%, dengan nilai loss yang sangat rendah yaitu 0.05, serta waktu pengujian lebih cepat (18 detik). Sementara itu, ResNet50V2 hanya mencapai akurasi 93% dengan loss 0.14 dan waktu pengujian sedikit lebih lama (19 detik).

3.2 Hasil Prediksi pada Gambar Uji

Pengujian lebih lanjut dilakukan terhadap sembilan gambar uji dari tiga kelas (Matang, Setengah Matang, dan Mentah). Hasil prediksi menunjukkan bahwa MobileNetV2 mampu menghasilkan prediksi yang lebih akurat dan konsisten dibandingkan ResNet50V2. Berikut ringkasan hasil prediksi.

Tabel 1. Hasil prediksi dan tingkat kepercayaan model MobileNetV2 dan ResNet50V2 pada gambar uji klasifikasi tingkat kematangan tomat.

| Gambar Uji | Mobilenetv2 | | Resnet50v2 | |
|---------------------|-----------------|-------------|-----------------|-------------|
| | prediksi | kepercayaan | prediksi | kepercayaan |
| Matang1.jpg | Matang | 98,38% | Matang | 77,66% |
| Matang2.jpg | Matang | 99,94% | Matang | 90,60% |
| Matang3.jpg | Matang | 99,99% | Matang | 97,93% |
| Setengahmatang1.jpg | Setengah Matang | 52,28 | Setengah Matang | 88,59% |
| Setengahmatang2.jpg | Setengah Matang | 93,49% | Setengah Matang | 99,98% |
| Setengahmatang3.jpg | Setengah Matang | 99,68% | Matang | 99,20% |
| Mentah1.jpg | Mentah | 100% | Mentah | 57,56% |
| Mentah2.jpg | Mentah | 100% | Mentah | 96,08% |
| Mentah3.jpg | Mentah | 99,94% | Matang | 99,27% |

Berdasarkan hasil pada tabel, MobileNetV2 berhasil mengklasifikasikan seluruh gambar uji dengan benar, meskipun pada gambar Setengahmatang1.jpg tingkat kepercayaannya hanya sebesar 52,28%. Hal ini menunjukkan bahwa meskipun model mampu mengenali kelas dengan tepat, terdapat ambiguitas dalam fitur visual gambar tersebut, yang mungkin disebabkan oleh pencahayaan, warna, atau sudut pengambilan gambar. Di sisi lain, prediksi MobileNetV2 untuk gambar lainnya menunjukkan tingkat kepercayaan yang sangat tinggi, bahkan mencapai 100% pada beberapa gambar kelas Mentah. Ini menandakan konsistensi dan keandalan model dalam mengenali fitur khas dari setiap tingkat kematangan tomat.

Sebaliknya, ResNet50V2 mengalami dua kesalahan klasifikasi, yaitu pada gambar Setengahmatang3.jpg dan Mentah3.jpg, yang keduanya secara keliru diklasifikasikan sebagai Matang dengan tingkat kepercayaan yang sangat tinggi (99,20% dan 99,27%). Kesalahan ini cukup signifikan karena menunjukkan bahwa model terlalu percaya diri terhadap prediksi yang salah. Hal ini juga mengindikasikan bahwa ResNet50V2 kesulitan membedakan fitur antara kelas Matang dengan dua kelas lainnya, terutama saat fitur visual antar kelas tidak terlalu kontras. Dengan demikian, secara keseluruhan, MobileNetV2 menunjukkan kinerja yang lebih unggul, baik dari sisi akurasi maupun kestabilan hasil prediksi terhadap data uji.

3.3 Evaluasi Metrik Klasifikasi

Untuk analisis lebih mendalam, digunakan metrik evaluasi lain seperti presisi, recall, dan F1-score. Hasilnya ditampilkan dalam tabel berikut.

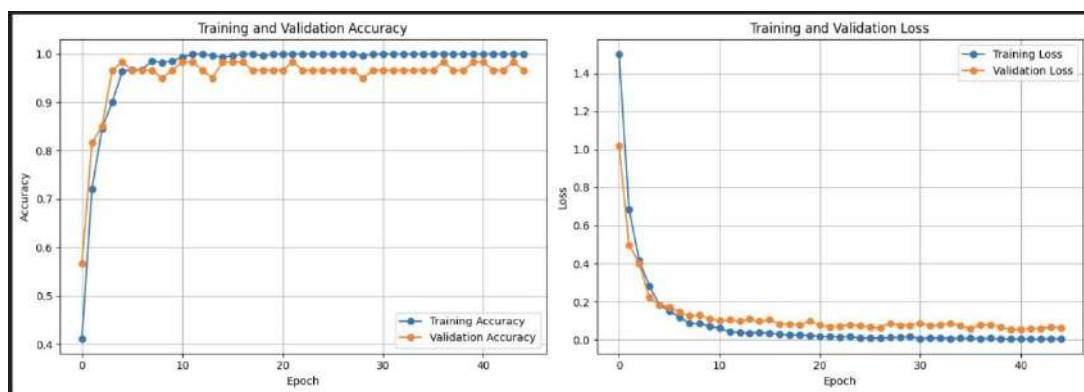
Tabel 3. Perbandingan metrik evaluasi (akurasi, presisi, recall, dan F1-score) antara model

| Model | Akurasi | Presisi | recall | F1-Score |
|-------------|---------|---------|--------|----------|
| Mobilenetv2 | 0,9833 | 0,9844 | 0,9833 | 0,9833 |
| Resnet50v2 | 0,9333 | 0,9339 | 0,9333 | 0,9320 |

Dari hasil di atas, MobileNet cocok untuk deployment pada perangkat edge, sementara ResNet unggul dalam akurasi untuk skenario klasifikasi kompleks dengan resource memadai. MobileNetV2 unggul di semua metrik, menunjukkan bahwa model ini tidak hanya akurat tetapi juga konsisten dalam mengenali setiap kelas. Performa ResNet50V2 cukup baik, namun terdapat penurunan pada akurasi dan F1-score yang mengindikasikan potensi overfitting atau kesulitan dalam membedakan kelas tertentu, terutama saat kondisi pencahayaan atau bentuk objek tidak ideal.


3.4 Visualisasi Proses Pelatihan Model ResNet50V2 & MobileNetV2

Grafik pelatihan model ResNet50V2 selama 45 epoch menunjukkan peningkatan akurasi yang signifikan sejak awal, di mana akurasi pelatihan melonjak dari sekitar 40% dan mencapai hampir 100% setelah epoch ke-15. Akurasi validasi pun stabil di atas 93% sejak epoch ke-10, menunjukkan kemampuan generalisasi model yang baik. Nilai loss pelatihan juga mengalami penurunan tajam dari sekitar 1,45 menjadi di bawah 0,1, dan loss validasi menunjukkan pola serupa meskipun sedikit lebih tinggi, tanpa tanda-tanda overfitting yang ekstrem. Secara keseluruhan, grafik ini mencerminkan bahwa ResNet50V2 mampu belajar secara efektif dan stabil, dengan hasil yang konsisten terhadap data validasi, selaras dengan metrik evaluasi sebelumnya yang menunjukkan akurasi 93,33% dan F1-score sebesar 0,9320.



Gambar 2. Visualisasi akurasi dan loss selama proses pelatihan dan validasi model Mobile ResNet50V2 selama 45 epoch.

Grafik pelatihan model MobileNetV2 selama 45 epoch menunjukkan peningkatan akurasi yang signifikan sejak awal, dengan akurasi pelatihan meningkat dari sekitar 60% dan dengan cepat melampaui 95%, kemudian stabil mendekati 100%. Akurasi validasi juga menunjukkan performa tinggi dan stabil, berada di atas 97% hingga akhir pelatihan. Sementara itu, grafik loss menunjukkan penurunan tajam dari sekitar 0,9 ke bawah 0,1 dalam waktu singkat pada data pelatihan, dan loss validasi mengikuti pola serupa dengan konsistensi yang baik serta fluktuasi kecil yang wajar. Kedua grafik menunjukkan bahwa proses pelatihan berjalan optimal tanpa indikasi underfitting maupun overfitting. Hasil ini selaras dengan metrik evaluasi yang diperoleh sebelumnya, di mana MobileNetV2 mencatatkan akurasi sebesar 98,33% dan F1-score sebesar 0,9833, membuktikan bahwa model sangat efektif dalam klasifikasi tingkat kematangan tomat.



Gambar 3. Visualisasi akurasi dan loss selama proses pelatihan dan validasi model MobileNetV2 selama 45 epoch.

4. KESIMPULAN

Penelitian ini membandingkan dua arsitektur deep learning populer, yaitu MobileNetV2 dan ResNet50V2, dalam tugas klasifikasi citra tomat berdasarkan tingkat kematangan (mentah, setengah matang, dan matang). Berdasarkan hasil evaluasi, MobileNetV2 menunjukkan performa yang lebih unggul dalam hal akurasi, kecepatan inferensi, dan efisiensi penggunaan sumber daya. Model ini mencapai akurasi sebesar 98,33% dengan waktu pengujian yang lebih cepat serta nilai presisi, recall, dan F1-score yang lebih tinggi dibandingkan ResNet50V2.

Sementara itu, ResNet50V2 tetap menunjukkan performa yang baik dengan akurasi sebesar 93,33%, namun mengalami beberapa kesalahan klasifikasi pada data uji dan membutuhkan waktu serta sumber daya komputasi yang lebih besar. Hal ini menunjukkan bahwa ResNet lebih cocok diterapkan pada sistem dengan kapasitas komputasi tinggi dan kebutuhan analisis citra kompleks.

Secara keseluruhan, dapat disimpulkan bahwa MobileNetV2 lebih direkomendasikan untuk implementasi pada sistem real-time dan perangkat edge yang membutuhkan efisiensi tinggi tanpa mengorbankan akurasi. Sedangkan ResNet50V2 tetap relevan untuk aplikasi dengan toleransi terhadap kompleksitas komputasi yang lebih besar dan fokus pada performa dalam skenario klasifikasi yang menantang.

REFERENSI

- [1] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, pp. 1–74, 2021, doi: 10.1186/s40537-021-00444-8.
- [2] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of image classification algorithms based on convolutional neural networks," *Remote Sens.*, vol. 13, no. 22, p. 4712, 2021, doi: 10.3390/rs13224712.
- [3] R. I. Borman, R. Napianto, N. Nugroho, D. Pasha, Y. Rahmanto, and Y. E. P. Yudoutomo, "Implementation of PCA and KNN algorithms in the classification of Indonesian medicinal plants," in *Proc. 2021 Int. Conf. Comput. Sci., Inf. Technol., Electr. Eng. (ICOMITEE)*, 2021, pp. 46–50, doi: 10.1109/ICOMITEE53461.2021.9650176.
- [4] A. Peryanto, D. Susanto, and Y. F. Widodo, "Klasifikasi citra bunga menggunakan metode support vector machine dan gray level co-occurrence matrix," *JIKA (Jurnal Informatika)*, vol. 9, no. 2, pp. 126–134, 2025, doi: 10.31000/jika.v9i2.13151.
- [5] I. Wulandari, H. Yasin, and T. Widiharah, "Klasifikasi citra digital bumbu dan rempah dengan algoritma convolutional neural network (CNN)," *J. Gaussian*, vol. 9, no. 3, pp. 273–282, 2020, doi: 10.14710/j.gauss.9.3.273-282.
- [6] Y. B. E. Purba, N. F. Saragih, A. P. Silalahi, S. Sitepu, and A. Gea, "Perancangan alat pendeteksi kematangan buah nanas dengan menggunakan mikrokontroler dengan metode convolutional neural network (CNN)," *Methotika: J. Ilm. Tek. Inform.*, vol. 2, no. 1, pp. 13–21, 2022.
- [7] A. Ridhovan and A. Suharso, "Penerapan metode residual network (ResNet) dalam klasifikasi penyakit pada daun gandum," *JUPI (J. Ilm. Penelit. Pembelajaran Inform.)*, vol. 7, no. 1, pp. 58–65, 2022, doi: 10.29100/jupi.v7i1.2410.
- [8] H. I. Fitriyani and M. Rizkinia, "Improvement of Xception-ResNet50V2 concatenation for COVID-19 detection on chest X-ray images," in *Proc. 2021 3rd East Indonesia Conf. Comput. Inf. Technol. (EIConCIT)*, 2021, pp. 343–347, doi: 10.1109/EIConCIT50028.2021.9431916.
- [9] D. Hastari, S. Winanda, A. R. Pratama, N. Nurhaliza, and E. S. Ginting, "Application of convolutional neural network ResNet-50 V2 on image classification of rice plant disease," *Public Res. J. Eng., Data Technol. Comput. Sci.*, vol. 1, no. 2, 2024, doi:
- [10] Z. Syahputra, "Penerapan SSD-MobileNet dalam identifikasi jenis buah apel," *Comput. Sci.*, vol. 1, no. 1, 2023, doi: 10.60076/indotech.v1i1.2.
- [11] G. Edel and V. Kapustin, "Exploring of the MobileNet V1 and MobileNet V2 models on NVIDIA Jetson Nano microcomputer," *J. Phys.: Conf. Ser.*, vol. 2291, no. 1, p. 012008, 2022, doi: 10.1088/1742-6596/2291/1/012008.

- [12] E. Prasetyo, R. Purbaningtyas, R. D. Adityo, N. Suciati, and C. Faticah, "Combining MobileNetV1 and depthwise separable convolution bottleneck with expansion for classifying the freshness of fish eyes," *Inf. Process. Agric.*, vol. 9, no. 4, pp. 485–496, 2022, doi: 10.1016/j.inpa.2022.01.002.
- [13] C. Sakunrasrisuay, P. Musikawan, A.-N. Nguyen, Y. Kongsorot, P. Aimtongkham, and C. So-In, "Tomato maturity classification: A transfer learning approach," in *Proc. 2021 25th Int. Comput. Sci. Eng. Conf. (ICSEC)*, 2021, pp. 411–416, doi: 10.1109/ICSEC53205.2021.9684584.