

Perbandingan VGG16, ResNet50, dan EfficientNet-B0 untuk Klasifikasi Kematangan Jeruk Bali

*Comparative Analysis of Transfer Learning-Based CNN Architectures for Pomelo Fruit
Ripeness Classification*

Raditya Bagja Saputra^{*1}, Asril Adi Sunarto^{*2}, Didik Indrayana^{*3}

Program Studi Teknik Informatika, Universitas Muhammadiyah Sukabumi

*E-mail : radityabagjasaputra045@ummi.ac.id^{*1}, asriladisunarto@ummi.ac.id^{*2},
didikindrayana@ummi.ac.id^{*3}*

**Corresponding author*

Received 27 June 2026; Revised 27 July 2026; Accepted 31 July 2026

Abstrak - Kematangan buah jeruk bali menentukan kualitas dan harga jualnya di pasaran, namun klasifikasi secara manual sering kali bersifat subjektif dan rawan kesalahan. Penelitian ini bertujuan untuk membandingkan performa tiga arsitektur Convolutional Neural Network (CNN) berbasis transfer learning, yaitu VGG16, ResNet50, dan EfficientNet-B0, dalam mengklasifikasikan kematangan jeruk bali ke dalam kategori matang dan belum matang. Sebanyak 700 gambar lokal digunakan dan dibagi dengan rasio 70:15:15 untuk data pelatihan, validasi, dan pengujian. Metode yang diusulkan meliputi praproses gambar, augmentasi data secara real-time, serta fine-tuning model menggunakan bobot ImageNet sebelum diimplementasikan ke dalam antarmuka web Streamlit. Hasil evaluasi pada 105 gambar uji menunjukkan bahwa VGG16 memperoleh akurasi tertinggi sebesar 96,19%. Model ResNet50 mencatatkan waktu inferensi tercepat, yaitu 103,98 ms/gambar dengan akurasi 94,29%, sementara EfficientNet-B0 memiliki ukuran penyimpanan paling efisien (30,3 MB) dengan akurasi 88,57%. Dapat disimpulkan bahwa arsitektur VGG16 merupakan solusi otomatis paling optimal untuk klasifikasi kematangan jeruk bali guna meminimalkan kerugian pascapanen.

Kata kunci - *Convolutional Neural Network, Kematangan Buah, Jeruk Bali, Transfer Learning, VGG16*

Abstract - *The maturity of pomelo fruit determines its quality and market price, yet manual classification is often subjective and error-prone. This study aims to compare the performance of three transfer learning-based Convolutional Neural Network (CNN) architectures VGG16, ResNet50, and EfficientNet-B0 in classifying pomelo maturity into unripe and ripe categories. A total of 700 local images were utilized, divided into a 70:15:15 ratio for training, validation, and testing sets. The proposed method involves image preprocessing, real-time data augmentation, and fine-tuning the models using ImageNet weights before implementation into a Streamlit web interface. Evaluation results on 105 test images revealed that VGG16 achieved the highest accuracy at 96.19%. The ResNet50 model recorded the fastest inference time of 103.98 ms/image with a 94.29% accuracy, while EfficientNet-B0 had the most efficient storage size (30.3 MB) with an 88.57% accuracy. In conclusion, the VGG16 architecture is the most optimal automated solution for classifying pomelo maturity to minimize post-harvest losses*

Keywords - *Convolutional Neural Network, Fruit Maturity, Pomelo, Transfer Learning, VGG16*

1. PENDAHULUAN

Jeruk Bali (*Citrus maxima*) merupakan komoditas buah tropis dengan ukuran lebih besar dibanding jenis jeruk pada umumnya, dan tersebar luas di Sumatera, Jawa, Bali, Kalimantan, serta Sulawesi [1]. Tingkat kematangan buah ini menjadi penentu utama kualitas dan harga jual di pasar, namun penentuannya secara manual masih bersifat subjektif dan rentan terhadap kesalahan interpretasi visual, terutama ketika menghadapi volume buah yang besar [2]. Kondisi ini

menimbulkan kebutuhan akan sistem otomatis yang akurat untuk mengklasifikasikan kematangan jeruk Bali demi efisiensi proses sortasi dan standarisasi mutu produk [3], sekaligus berpotensi meminimalkan kerugian pascapanen akibat kesalahan klasifikasi [4].

Convolutional Neural Network (CNN) menawarkan solusi komputasi yang objektif untuk mengolah data visual buah, karena kemampuannya mengekstraksi fitur kompleks secara otomatis dari citra [2];[5]. Pendekatan ini telah terbukti efektif pada berbagai kasus klasifikasi kematangan buah tropis lain, misalnya akurasi 95% pada pisang dengan Inception V3 [3] dan 96% pada jeruk manis [2]. Untuk mengatasi keterbatasan data latih yang relatif kecil, *transfer learning* dimanfaatkan untuk mempercepat pelatihan dan meningkatkan kinerja model dengan memanfaatkan bobot dari model yang telah dilatih pada dataset besar seperti ImageNet [6];[7]. Penerapan *transfer learning* pada arsitektur seperti VGG16 telah menunjukkan performa yang baik pada klasifikasi kematangan buah lain, dengan akurasi mencapai 98% pada kasus manggis, alpukat, apel, dan jeruk [8].

Sejumlah penelitian terdahulu memperkuat relevansi pendekatan ini namun juga memperlihatkan kesenjangan yang belum terjawab. [9] membandingkan VGG16 dan MobileNetV2 untuk kematangan apel dengan akurasi hingga 98%, namun belum menguji arsitektur yang lebih efisien seperti EfficientNet maupun ResNet50. [10] menerapkan CNN Xception pada kelapa sawit dengan akurasi 90%, tetapi terbatas pada dua kelas tanpa pembanding arsitektur lain. [11] mengklasifikasikan kematangan pisang secara *real-time* berbasis Android namun tanpa rincian arsitektur CNN maupun penerapan *transfer learning*, sementara penelitian pada stroberi [12] menggunakan objek buah yang berbeda tanpa *transfer learning*. Secara umum, studi komparatif yang sistematis antararsitektur CNN berbasis *transfer learning* khusus pada jeruk Bali dengan dataset lokal masih belum ditemukan.

Klasifikasi kematangan jeruk Bali memiliki tantangan visual yang berbeda dibandingkan dengan komoditas buah lain yang telah diteliti sebelumnya. Berbeda dengan apel atau kelapa sawit yang memiliki perubahan warna kulit relatif tajam antara fase mentah dan matang, jeruk Bali menunjukkan transisi warna kulit yang lebih gradual dari hijau tua ke kuning kehijauan, dengan rentang warna transisi yang cukup lebar sehingga sulit dibedakan hanya berdasarkan ambang warna sederhana. Selain itu, tekstur kulit jeruk Bali yang berpori dan bertekstur kasar (dibandingkan permukaan kulit apel yang relatif halus) turut menambah kompleksitas ekstraksi fitur visual. Kondisi pengambilan gambar dari perkebunan dan pasar lokal juga menghadirkan variasi pencahayaan alami serta latar belakang yang tidak seragam, berbeda dengan kondisi studio terkontrol pada sebagian penelitian terdahulu. Karakteristik ini menjadikan perbandingan arsitektur CNN pada objek jeruk Bali relevan untuk diteliti, karena kemampuan tiap arsitektur dalam menangkap tekstur permukaan dan gradasi warna yang halus berpotensi menghasilkan perbedaan performa yang signifikan antarmodel.


Berdasarkan kesenjangan tersebut, penelitian ini bertujuan menganalisis dan membandingkan performa tiga arsitektur CNN berbasis *transfer learning* — VGG16, ResNet50, dan EfficientNet-B0 — dalam mengklasifikasikan tingkat kematangan jeruk Bali ke dalam dua kelas (mentah dan matang) menggunakan dataset lokal sebanyak 700 citra. Kontribusi utama penelitian ini adalah perbandingan empiris ketiga arsitektur tersebut berdasarkan akurasi, F1-score, dan efisiensi komputasi, sebagai dasar penentuan arsitektur paling optimal untuk diimplementasikan pada kasus klasifikasi kematangan jeruk Bali.

2. METODE PENELITIAN

2.1. Metode Penelitian

Penelitian ini menggunakan metode eksperimental komparatif dengan pendekatan kuantitatif untuk membandingkan performa tiga arsitektur *Convolutional Neural Network* (CNN) berbasis *transfer learning* dalam mengklasifikasikan kematangan jeruk Bali. Metode eksperimental dipilih karena penelitian ini melibatkan pengujian sistematis terhadap beberapa model *deep learning* dalam kondisi terkontrol untuk menemukan arsitektur paling optimal [13].

Pendekatan komparatif memungkinkan perbandingan objektif antar arsitektur dengan mengontrol variabel lain seperti dataset, *preprocessing*, augmentasi data, dan konfigurasi *training* [14]. Variabel independen dalam penelitian ini adalah arsitektur CNN (VGG16, ResNet50, dan EfficientNet-B0), sedangkan variabel dependennya adalah akurasi klasifikasi kematangan buah.



Gambar 1. Diagram Alur Penelitian

2.2. Dataset Penelitian

Dataset yang digunakan berjumlah 700 citra jeruk Bali, terbagi rata pada dua kategori kematangan: mentah (kulit hijau tua, tekstur keras) dan matang (kulit kuning cerah, siap konsumsi). Setiap citra diberi label manual dan divalidasi untuk memastikan akurasi pelabelan sebelum memasuki tahap *preprocessing*.



Gambar 2. Contoh Citra Mentah & Matang

2.3. Preprocessing dan Augmentasi Data

Tahap *preprocessing* meliputi penyesuaian ukuran seluruh citra menjadi 224×224 piksel sesuai standar input ketiga arsitektur, konversi ke format RGB 3 *channel*, dan normalisasi nilai piksel dari rentang 0–255 menjadi 0–1 untuk menstabilkan proses pelatihan. Untuk meningkatkan keragaman data dan mencegah *overfitting*, augmentasi diterapkan secara *real-time* [15] berupa rotasi acak ($\pm 15^\circ$), pergeseran horizontal/vertikal ($\pm 10\%$), *horizontal flipping*, *zoom* acak (0.8–1.2), serta penyesuaian *brightness* dan kontras. Dataset selanjutnya dibagi dengan rasio 70:15:15

untuk *training*, *validation*, dan *testing* menggunakan *stratified splitting* agar distribusi kelas tetap proporsional pada setiap subset.

2.4. Implementasi Arsitektur CNN dan Transfer Learning

Tiga arsitektur CNN *pre-trained* diimplementasikan menggunakan bobot ImageNet melalui skema *transfer learning*: VGG16 (13 lapisan konvolusi, 138 juta parameter), ResNet50 (50 lapisan dengan *residual connections* untuk mengatasi *vanishing gradient*, 23 juta parameter), dan EfficientNet-B0 (*compound scaling method*, 5 juta parameter, paling efisien secara komputasi). Proses *training* dilakukan dalam dua tahap: tahap pertama melatih *classifier* dengan *convolutional base* dibekukan (*feature extraction*), dan tahap kedua melakukan *fine-tuning* dengan membuka beberapa lapisan akhir menggunakan *learning rate* lebih kecil (0.00001) agar model beradaptasi secara spesifik terhadap domain data. Konfigurasi *training* untuk ketiga model menggunakan *optimizer* Adam (*learning rate* 0.0001), fungsi *loss* *categorical crossentropy*, *batch size* 32, dan maksimal 100 *epoch* dengan *early stopping* (*patience* = 10). Seluruh proses pelatihan dijalankan pada *Google Colaboratory* dengan akselerasi GPU (Tesla T4/V100) menggunakan *framework* TensorFlow 2.13.0.

Nilai *learning rate* 0,0001 pada tahap *feature extraction* dan 0,00001 pada tahap *fine-tuning* ditentukan berdasarkan uji coba awal (*preliminary trial*) pada beberapa kandidat nilai (0,001; 0,0001; 0,00001), dengan mempertimbangkan rekomendasi umum pada literatur *transfer learning* yang menyarankan *learning rate* lebih kecil saat *fine-tuning* untuk menghindari *catastrophic forgetting* terhadap bobot *pre-trained* ImageNet [7]. Nilai 0,0001 dipilih untuk tahap awal karena memberikan konvergensi yang stabil pada *classifier* baru, sedangkan nilai 0,00001 (10 kali lebih kecil) digunakan pada tahap *fine-tuning* agar penyesuaian bobot pada lapisan konvolusi akhir berlangsung secara bertahap tanpa merusak fitur yang telah dipelajari sebelumnya.


2.5. Evaluasi Model

Evaluasi performa ketiga model dilakukan pada data *testing* menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, dilengkapi *confusion matrix* untuk melihat distribusi prediksi per kelas. Selain metrik akurasi, efisiensi komputasi turut diukur melalui waktu *training* dan waktu *inference* per citra, sebagai pertimbangan praktis kelayakan implementasi model pada sistem klasifikasi otomatis.

3. HASIL DAN PEMBAHASAN


3.1. Hasil Implementasi dan Evaluasi Model

Ketiga arsitektur CNN dilatih menggunakan skema *transfer learning* dua tahap (*feature extraction* lalu *fine-tuning*) dan dievaluasi pada 105 citra *test set* yang tidak pernah dilihat selama pelatihan. Model VGG16 dilatih selama 50 *epoch* dan mencapai *val_accuracy* terbaik sebesar 98,96% pada *epoch* ke-39, dengan kurva *loss training* dan validasi yang konvergen tanpa indikasi *overfitting* signifikan. Model ResNet50 dilatih selama total 81 *epoch* (43 *epoch feature extraction* + 38 *epoch fine-tuning*) dengan *best validation accuracy* 95,83% pada *epoch* ke-33, sedangkan EfficientNet-B0 dilatih selama 79 *epoch* (39 + 40) dengan *best validation accuracy* 93,75% pada *epoch* ke-29. Perbandingan kurva *training history* ketiga model disajikan pada Gambar 3.



Gambar 3. Perbandingan Kurva Training History VGG16, ResNet50, Efficient-B0

Pada evaluasi *test set*, VGG16 mencapai akurasi tertinggi sebesar 96,19% (101/105 benar, F1-score 0,9619), dengan *recall* sempurna (1,0000) pada kelas matang — seluruh 52 citra matang teridentifikasi benar, dan hanya 4 kesalahan pada kelas mentah yang diprediksi matang. ResNet50 mencapai akurasi 94,29% (99/105 benar, F1-score 0,9427), dengan 6 kesalahan klasifikasi (1 mentah→matang, 5 matang→mentah). EfficientNet-B0 mencapai akurasi terendah sebesar 88,57% (93/105 benar, F1-score 0,8849), dengan 12 kesalahan klasifikasi yang didominasi kelas matang diprediksi mentah (10 kasus). Visualisasi *confusion matrix* ketiga model disajikan pada Gambar 4.



Gambar 4. Visualisasi Confusion Matrix VGG16, ResNet50, EfficientNet-B0

3.2. Perbandingan Performa dan Efisiensi Komputasi

Rekapitulasi perbandingan ketiga model berdasarkan akurasi, *F1-score*, waktu inferensi, ukuran model, dan jumlah parameter disajikan pada Tabel 1.

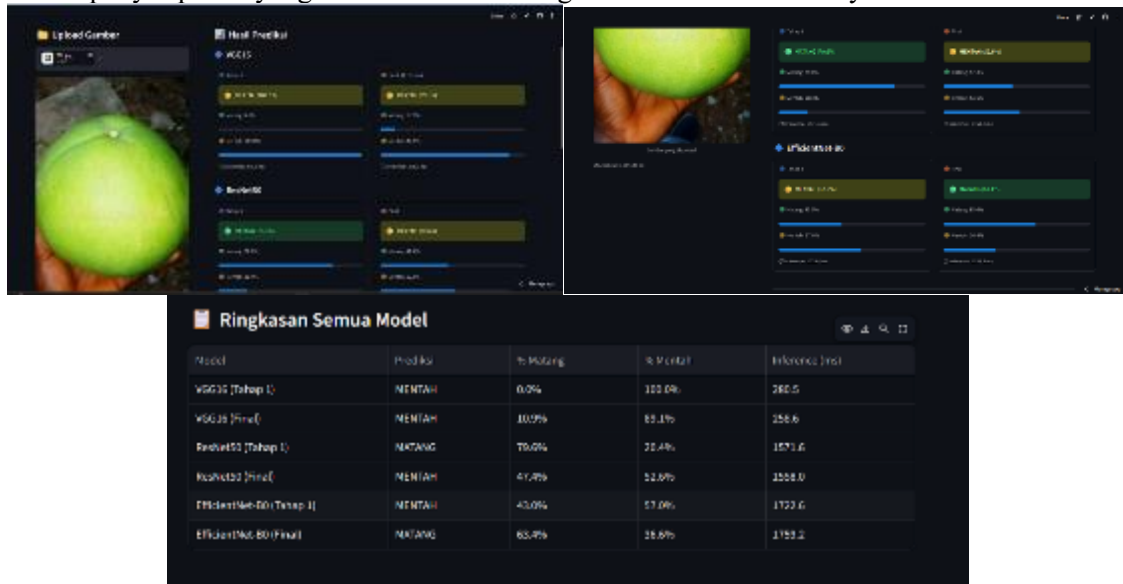
Tabel 1. Perbandingan Performa Ketiga Model CNN

Metrik	VGG16	ResNet50	EfficientNet-B0
<i>Accuracy</i>	96,19%	94,29%	88,57%
<i>F1-score</i>	0,916	0,9427	0,8849
Waktu Inferensi	182,07 ms/citra	103,98 ms/citra	233,14 ms/citra
Ukuran Model	147,8 MB	138,7 MB	30,3 MB
Total Parameter	14.846.530	24.112.770	4.378.021

Hasil pada Tabel 1 menunjukkan bahwa tidak ada satu model yang superior di seluruh aspek, melainkan masing-masing arsitektur unggul pada dimensi berbeda. VGG16 mencatat akurasi dan *F1-score* tertinggi, didukung oleh ekstraksi fitur hierarkis dengan filter konvolusi 3×3 yang konsisten, sehingga efektif membedakan tekstur dan warna kulit jeruk Bali pada kedua kategori. ResNet50, meskipun memiliki jumlah parameter terbanyak (24,1 juta), mencatat waktu inferensi tercepat (103,98 ms/citra) — hal ini sejalan dengan karakteristik *residual connections* yang memungkinkan aliran komputasi gradien lebih efisien tanpa degradasi performa pada GPU. EfficientNet-B0 unggul signifikan dari sisi efisiensi penyimpanan, dengan ukuran model hanya 30,3 MB (kurang dari seperempat ukuran VGG16), berkat pendekatan *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara proporsional — namun trade-off-nya adalah akurasi terendah di antara ketiga model. Dibandingkan dengan penelitian terdahulu yang dibahas pada bagian Introduction, akurasi VGG16 pada penelitian ini (96,19%) sebanding dengan hasil [9] pada apel (98%) dan lebih tinggi dibandingkan [10] pada kelapa sawit (90%), mengindikasikan bahwa pendekatan *transfer learning* berbasis VGG16 konsisten efektif untuk klasifikasi kematangan buah lintas-komoditas, termasuk pada objek jeruk Bali yang belum diuji pada studi-studi sebelumnya. Keunggulan VGG16 pada klasifikasi jeruk Bali kemungkinan berkaitan dengan kemampuan filter konvolusi 3×3 berlapis dalam menangkap detail tekstur kulit yang berpori, sementara arsitektur dengan downsampling lebih agresif seperti EfficientNet-B0 berpotensi kehilangan detail tekstur halus tersebut pada resolusi fitur yang lebih rendah. Meskipun EfficientNet-B0 memiliki jumlah parameter paling sedikit (4,4 juta) dan ukuran model terkecil (30,3 MB), model ini justru mencatat waktu inferensi paling lambat (233,14 ms/citra) dibandingkan VGG16 (182,07 ms/citra) dan ResNet50 (103,98 ms/citra). Temuan ini tampak kontra-intuitif mengingat efisiensi komputasi EfficientNet-B0 secara teoritis, namun dapat dijelaskan melalui beberapa faktor teknis. Pertama, EfficientNet-B0 menggunakan *depthwise separable convolutions* sebagai komponen utama arsitekturnya, yang meskipun mengurangi jumlah parameter dan FLOPs secara signifikan, memiliki intensitas aritmetika (*arithmetic intensity*) yang lebih rendah dibandingkan konvolusi standar. Operasi ini kurang optimal untuk diproses secara paralel pada GPU, karena kernel CUDA/cuDNN pada *framework* seperti TensorFlow secara historis lebih teroptimasi untuk konvolusi standar (seperti yang digunakan VGG16 dan ResNet50) dibandingkan *depthwise convolutions* [13]. Kedua, EfficientNet-B0 menggunakan fungsi aktivasi *Swish* yang secara komputasi lebih kompleks dibandingkan *ReLU* yang digunakan VGG16 dan ResNet50, menambah overhead komputasi per operasi. Ketiga, pengujian inferensi pada penelitian ini dilakukan secara *single-image* (*batch size* 1) tanpa optimasi *batching*, sehingga keunggulan efisiensi parameter EfficientNet-B0 — yang idealnya termanifestasi pada throughput *batch* besar atau perangkat *edge* dengan keterbatasan memori — tidak tercermin pada skenario inferensi satu-per-satu di lingkungan Google Colab. Dengan demikian, anomali ini lebih mencerminkan karakteristik optimasi *framework* dan skenario pengujian dibandingkan kelemahan intrinsik arsitektur EfficientNet-B0 itu sendiri, dan berpotensi menunjukkan hasil berbeda apabila diuji dengan *batch inference* atau pada perangkat *edge* yang dioptimalkan khusus untuk *depthwise convolutions* seperti TensorFlow Lite pada perangkat mobile.

3.3. Implementasi Praktis Menggunakan Streamlit

Sebagai validasi penerapan, ketiga model diintegrasikan ke dalam antarmuka web berbasis *framework* Streamlit yang memuat ketiga model secara simultan dan menampilkan hasil prediksi komparatif beserta *confidence score* dan waktu inferensi untuk setiap model secara *real-time*, sebagaimana ditunjukkan pada Gambar 5. Berdasarkan keseluruhan hasil pengujian, VGG16 ditetapkan sebagai model paling optimal untuk diterapkan dalam sistem klasifikasi kematangan jeruk Bali, karena *recall* sempurna pada kelas matang (1,0000) meminimalisir risiko buah mentah yang salah diklasifikasikan sebagai matang — faktor krusial untuk mencegah kerugian pasca-panen di tingkat petani maupun industri, meskipun model ini mengorbankan ukuran penyimpanan yang lebih besar dibandingkan dua arsitektur lainnya.



Gambar 5. Hasil Implementasi Model VGG16, ResNet50, dan EfficientNet-B0

4. KESIMPULAN

Penelitian ini berhasil membandingkan performa tiga arsitektur CNN berbasis *transfer learning* VGG16, ResNet50, dan EfficientNet-B0 dalam mengklasifikasikan kematangan jeruk Bali ke dalam dua kelas (mentah dan matang), sebagaimana ditujukan pada bagian Introduction. Hasil pengujian pada 105 citra *test set* menunjukkan bahwa VGG16 mencapai akurasi tertinggi sebesar 96,19% dengan F1-score 0,9619, mengungguli ResNet50 (94,29%) dan EfficientNet-B0 (88,57%), sekaligus membuktikan bahwa pendekatan *transfer learning* berbasis bobot *pre-trained* ImageNet efektif diterapkan pada dataset lokal berskala relatif kecil (700 citra) tanpa indikasi *overfitting* yang signifikan. Temuan ini menjawab kesenjangan penelitian terdahulu yang belum menghadirkan studi komparatif sistematis antar-arsitektur CNN khusus pada objek jeruk Bali. Ditinjau secara komprehensif, VGG16 ditetapkan sebagai arsitektur paling optimal untuk implementasi karena *recall* sempurna pada kelas matang, sedangkan ResNet50 menjadi alternatif terbaik apabila kecepatan inferensi menjadi prioritas (103,98 ms/citra). Pengembangan lebih lanjut disarankan mencakup perluasan variasi dataset dengan latar belakang lapangan yang lebih kompleks serta penambahan kelas baru seperti kategori setengah matang (*intermediate ripeness*) untuk mengakomodasi fase transisi kematangan yang sering dijumpai pada kondisi pasca-panen di lapangan, maupun kategori busuk atau terkena penyakit untuk mendekati kondisi operasional yang lebih realistis, optimasi *hyperparameter* melalui *grid search*, pengembangan fitur deteksi *real-time* berbasis *live video stream*, serta penambahan mekanisme validasi *out-of-distribution* pada antarmuka web agar sistem lebih *robust* terhadap input di luar domain jeruk Bali.

REFERENSI

- [1] J. A. Pariury, J. Paul Christian Herman, T. Rebecca¹, E. Veronica, G. Kamasan, and N. Arijana, “HANG TUAH MEDICAL JOURNAL Potensi Kulit Jeruk Bali (Citrus Maxima Merr) Sebagai Antibakteri Propionibacterium acne Penyebab Jerawat,” 2021. [Online]. Available: www.journal-medical.hangtuah.ac.id
- [2] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, “Penerapan Algoritma Deep Learning Convolutional Neural Network Dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB),” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 1, pp. 59–66, Feb. 2023, doi: 10.25126/jtiik.2023105695.
- [3] N. W. Wulansari and M. Muslih, “Implementasi Metode Convolutional Neural Network Untuk Deteksi Kematangan Buah Pisang Menggunakan Inception V3,” *JOINS (Journal of Information System)*, vol. 8, no. 2, pp. 147–155, Nov. 2023, doi: 10.33633/joins.v8i2.9074.
- [4] M. Han and C. Yi, “Deep Convolutional Neural Networks for Palm Fruit Maturity Classification,” Feb. 2025, [Online]. Available: <http://arxiv.org/abs/2502.20223>
- [5] A. J. Rozaqi, A. Sunyoto, and M. R. Arief, “Seminar Nasional & Call Paper Fakultas Sains dan Teknologi (SENASAINS 1 st,” 2021.
- [6] N. P. Sutrisna *et al.*, “Deteksi Tingkat Kematangan Buah Pepaya menggunakan Model Convolutional Neural Network,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 3, pp. 569–578, Jul. 2024, doi: 10.25126/jtiik.938119.
- [7] B. D. Pérez-Pérez, J. P. García Vázquez, and R. Salomón-Torres, “Evaluation of convolutional neural networks’ hyperparameters with transfer learning to determine sorting of ripe medjool dates,” *Agriculture (Switzerland)*, vol. 11, no. 2, pp. 1–12, Feb. 2021, doi: 10.3390/agriculture11020115.
- [8] A. Luthfiarta, “VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification,” *Jurnal Informatika dan Teknologi Informasi*, vol. 18, no. 1, pp. 37–48, 2021, doi: 10.31515/telematika.v18i1.4025.
- [9] A. Ivani *et al.*, “Perbandingan VGG16 dan MobileNetV2 untuk Klasifikasi Tingkat Kematangan Buah Apel,” 2025.
- [10] I. Afandy, B. N. Ahmad, and M. R. Amartharizqi, “Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network (CNN) Dengan Transfer Learning Xception,” *Jurnal Ilmiah Teknologi Informasi dan Robotika*, vol. 6, no. 2, pp. 88–98, Dec. 2024, doi: 10.33005/jifti.v6i2.158.
- [11] R. Soekarta, M. Fadli Hasa, and E. S. Ode, “Klasifikasi Kematangan Buah Pisang Secara Real-Time Menggunakan Convolutional Neural Network Berbasis Android,” vol. 10, no. 01, 2024.
- [12] Zahrotul Ilmi Wijayanti, “Penerapan Teknologi CNN Dalam Proses Pendeteksi Kematangan Buah Stroberi,” *Uranus : Jurnal Ilmiah Teknik Elektro, Sains dan Informatika*, vol. 2, no. 3, pp. 01–12, Jul. 2024, doi: 10.61132/uranus.v2i3.192.
- [13] L. Alzubaidi *et al.*, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,” *J. Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00444-8.
- [14] M. M. Taye, “Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions,” May 01, 2023, *MDPI*. doi: 10.3390/computers12050091.
- [15] Wildan Amin Wiharja, Tohirin Al Mudzakir, Hilda Yulia Novita, and Jamaludin Indra, “Perbandingan Algoritma Logistic Regression dan K-Nearest Neighbor Dalam Klasifikasi Kematangan Buah Pepaya,” *Bulletin of Computer Science Research*, vol. 5, no. 4, pp. 353–360, Jun. 2025, doi: 10.47065/bulletincsr.v5i4.550.