

KLASIFIKASI KEMATANGAN BUAH TOMAT BERBASIS CNN DENGAN ARSITEKTUR MOBILENETV2 DAN *TRANSFER LEARNING*

Mochamad Fathur Milzam Ramadhan¹⁾, Ahmad Syukri Gozali²⁾, Sumanto³⁾,
Jefina Tri Kumalasari⁴⁾, Ghofar Taufiq⁵⁾, Ade Christian⁶⁾

Prodi Informatika, Fakultas Teknik & Informatika, Universitas Bina Sarana Informatika

Correspondence author: MFM Ramadhan, 15230498@bsi.ac.id, Bekasi, Indonesia

Abstract

Classifying tomato ripeness is a crucial aspect of post-harvest processing and agricultural distribution. Manual ripeness determination is subjective and potentially inconsistencies. This study aims to classify tomato ripeness using a deep learning approach based on a Convolutional Neural Network (CNN) with the MobileNetV2 architecture and transfer learning techniques. The dataset, consisting of tomato images, was classified into three classes: unripe, ripe, and overripe. Preprocessing included image resizing and normalization before model training. The MobileNetV2 model was used as a feature extractor, while a fully connected layer was applied for classification. Test results showed that the model was able to classify tomato ripeness with good performance based on classification evaluation metrics. Overall, the proposed approach shows good potential for RGB image-based tomato ripeness classification.

Keyword : classification algorithm, ripeness, tomato, CNN, MobileNetV2

Abstrak

Klasifikasi tingkat kematangan buah tomat merupakan aspek penting dalam proses pascapanen dan distribusi hasil pertanian. Penentuan kematangan secara manual masih bersifat subjektif dan berpotensi menimbulkan ketidakkonsistenan. Penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan buah tomat menggunakan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 dan teknik *transfer learning*. Dataset berupa citra buah tomat diklasifikasikan ke dalam tiga kelas, yaitu tidak matang, matang, dan terlalu matang. Tahapan *preprocessing* meliputi proses *resizing* dan normalisasi citra sebelum dilakukan pelatihan model. Model MobileNetV2 digunakan sebagai *feature extractor*, sedangkan lapisan *fully connected* diterapkan untuk proses klasifikasi. Hasil pengujian menunjukkan bahwa model mampu mengklasifikasikan tingkat kematangan buah tomat dengan performa yang baik berdasarkan metrik evaluasi klasifikasi. Secara keseluruhan, pendekatan yang diusulkan menunjukkan potensi yang baik untuk klasifikasi tingkat kematangan buah tomat berbasis citra RGB.

Kata Kunci : algoritma klasifikasi, tingkat kematangan, buah tomat, cnn, mobilnetv2

A. PENDAHULUAN

Buah tomat merupakan salah satu komoditas hortikultura yang memiliki tingkat produksi dan konsumsi yang tinggi, baik untuk kebutuhan rumah tangga maupun industri pangan. Tomat digunakan dalam berbagai produk olahan, seperti saus, jus, dan bahan masakan, sehingga kualitas buah tomat menjadi faktor penting dalam menjaga kepuasan konsumen. Salah satu indikator utama kualitas buah tomat adalah tingkat kematangannya, karena tingkat kematangan berpengaruh terhadap rasa, tekstur, warna, serta daya simpan buah selama proses distribusi dan penyimpanan (Santoso et al., 2024).

Dalam praktik pascapanen, penentuan tingkat kematangan buah tomat masih banyak dilakukan secara manual melalui pengamatan visual oleh manusia. Penilaian tersebut umumnya didasarkan pada perubahan warna kulit buah dari hijau menuju merah. Meskipun metode ini mudah diterapkan, penilaian manual bersifat subjektif dan bergantung pada pengalaman pengamat, sehingga berpotensi menimbulkan ketidakkonsistenan hasil, terutama ketika dilakukan dalam skala besar atau oleh banyak pekerja dengan tingkat pengalaman yang berbeda (Ayunda et al., 2023).

Seiring dengan perkembangan teknologi, pengolahan citra digital menjadi salah satu pendekatan yang banyak digunakan untuk membantu proses klasifikasi objek secara otomatis. Citra digital mampu merepresentasikan karakteristik visual suatu objek dalam bentuk data numerik, termasuk warna, tekstur, dan bentuk. Dalam konteks buah tomat, informasi warna pada citra RGB menjadi parameter penting karena perubahan warna merupakan ciri utama dalam proses pematangan buah. Oleh karena itu, pemanfaatan citra RGB banyak diterapkan dalam penelitian klasifikasi tingkat kematangan buah (Santoso et al., 2024).

Pendekatan berbasis *machine learning* telah digunakan dalam berbagai penelitian

untuk mengklasifikasikan tingkat kematangan buah tomat (Choirunisa & Supatman, 2025; Fajar et al., 2023; Husna & Fatah, 2026). Namun, metode konvensional umumnya memerlukan proses ekstraksi fitur secara manual, seperti perhitungan nilai warna atau tekstur tertentu, yang membutuhkan perancangan fitur secara khusus dan bergantung pada pengetahuan domain. Keterbatasan tersebut mendorong penggunaan pendekatan *deep learning* yang mampu melakukan ekstraksi fitur secara otomatis dari data citra (Samual & Wijanarko, 2026).

Convolutional Neural Network (CNN) merupakan salah satu metode *deep learning* yang paling banyak digunakan dalam klasifikasi citra. CNN bekerja dengan memanfaatkan lapisan konvolusi untuk mengekstraksi fitur visual secara bertingkat, sehingga mampu mengenali pola kompleks pada citra digital. Berbagai penelitian menunjukkan bahwa CNN memberikan performa yang baik dalam tugas klasifikasi citra di bidang pertanian, termasuk identifikasi jenis tanaman, deteksi penyakit tanaman, dan klasifikasi tingkat kematangan buah (Mardianto et al., 2024).

Meskipun CNN mampu menghasilkan performa yang baik, penggunaan arsitektur CNN konvensional dengan jumlah parameter yang besar sering kali memerlukan sumber daya komputasi yang tinggi dan waktu pelatihan yang relatif lama. Hal ini menjadi kendala apabila sistem akan diterapkan pada perangkat dengan keterbatasan sumber daya atau pada aplikasi yang membutuhkan efisiensi. Untuk mengatasi permasalahan tersebut, pendekatan *transfer learning* menjadi solusi yang banyak digunakan dalam pengembangan model klasifikasi citra (Saparudin et al., 2025).

Transfer learning memungkinkan pemanfaatan model CNN yang telah dilatih sebelumnya pada dataset berskala besar, sehingga proses pelatihan dapat dilakukan dengan lebih cepat dan stabil. Salah satu arsitektur CNN yang dirancang untuk

efisiensi adalah MobileNetV2. Arsitektur ini menggunakan *depthwise separable convolution* dan *inverted residual blocks* yang mampu mengurangi jumlah parameter serta beban komputasi tanpa mengurangi kemampuan model dalam mengekstraksi fitur penting dari citra (Rumbekwan & Aryanto, 2025).

Tujuan dari penelitian ini adalah untuk mengembangkan sistem klasifikasi tingkat kematangan buah tomat berbasis citra RGB menggunakan pendekatan *deep learning*. Secara khusus, penelitian ini bertujuan untuk menerapkan arsitektur MobileNetV2 dengan teknik *transfer learning* sebagai metode klasifikasi, serta mengevaluasi kinerja model dalam mengklasifikasikan buah tomat ke dalam tiga kelas tingkat kematangan, yaitu tidak matang, matang, dan terlalu matang.

Keterbaruan dari penelitian ini terletak pada penerapan arsitektur MobileNetV2 berbasis *transfer learning* sebagai metode klasifikasi tingkat kematangan buah tomat menggunakan citra RGB. Pemanfaatan arsitektur CNN yang ringan memungkinkan proses pelatihan model yang lebih efisien dengan jumlah parameter yang relatif lebih sedikit, tanpa mengorbankan performa klasifikasi. Selain itu, penelitian ini menerapkan pembagian data secara otomatis dan terstruktur untuk proses pelatihan, validasi, dan pengujian, sehingga evaluasi kinerja model dapat dilakukan secara lebih objektif dan terukur. Pendekatan yang digunakan dalam penelitian ini diharapkan dapat memberikan alternatif solusi yang efisien untuk sistem klasifikasi kematangan buah tomat berbasis citra digital.

B. METODE PENELITIAN

Penelitian ini menerapkan pendekatan eksperimental menggunakan pengolahan citra digital dan *deep learning* untuk klasifikasi tingkat kematangan buah tomat. Metode utama yang digunakan adalah *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 melalui

pendekatan *Transfer Learning*. Penggunaan arsitektur ini dipilih karena efisiensinya dalam mengekstraksi fitur visual secara otomatis serta kemampuannya dalam mengenali pola tekstur yang kompleks dengan sumber daya komputasi yang efisien.

Dataset Penelitian

Dataset yang digunakan dalam penelitian ini terdiri dari 821 citra buah tomat yang terbagi ke dalam tiga kelas tingkat kematangan, yaitu tidak matang, matang, dan terlalu matang. Seluruh citra dikumpulkan dalam satu direktori utama sebelum dilakukan pembagian data secara otomatis. Dataset kemudian dibagi menjadi data latih, data validasi, dan data uji dengan rasio 8:1:1, sehingga diperoleh sekitar 80% data untuk pelatihan, serta masing-masing 10% data untuk validasi dan pengujian. Pembagian ini bertujuan untuk memastikan bahwa model dilatih menggunakan data yang cukup, sekaligus dievaluasi menggunakan data uji yang benar-benar terpisah guna mengukur kemampuan generalisasi model secara objektif. Seluruh citra menggunakan ruang warna RGB sebagai representasi standar yang umum digunakan dalam analisis berbasis warna (Santoso et al., 2024).

Berdasarkan pembagian tersebut, data uji terdiri dari sekitar 80 citra tomat yang digunakan secara khusus untuk mengevaluasi performa model setelah proses pelatihan selesai. Penggunaan data uji yang terpisah memungkinkan pengukuran kinerja model secara lebih objektif terhadap citra yang belum pernah dilihat sebelumnya. Rincian jumlah data yang digunakan adalah sebagai berikut:

Kategori Data	Matang	Terlalu Matang	Tidak Matang	Total
Data Latih (<i>Training</i>)	344	86	226	656
Data Validasi (<i>Validation</i>)	43	11	28	82
Data Uji (<i>Testing</i>)	36	9	40	85
Total Keseluruhan	423	106	294	823

Gambar 1. Rincian dataset

Pembagian ini memastikan bahwa model diuji pada data yang benar-benar independen (data uji) untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

```
dataset/  
  test/  
    matang/  
    terlalu_matang/  
    tidak_matang/  
  train/  
    matang/  
    terlalu_matang/  
    tidak_matang/  
  valid/  
    matang/  
    terlalu_matang/  
    tidak_matang/
```

Gambar 2. Struktur dataset

Praproses data

Pada tahap praproses, seluruh citra diubah ukurannya menjadi 224×224 piksel agar memiliki dimensi yang seragam sebagai masukan model CNN. Selanjutnya, nilai intensitas piksel dinormalisasi ke rentang $[0,1]$ untuk membantu proses pelatihan model menjadi lebih stabil dan mempercepat konvergensi.

Selain itu, dilakukan data augmentation pada data latih untuk meningkatkan variasi data dan mengurangi risiko *overfitting*. Teknik augmentasi ini bertujuan agar model tidak hanya bergantung pada pola tertentu dari dataset asli, sehingga mampu mengenali variasi tampilan buah tomat yang lebih beragam. Pendekatan ini umum diterapkan dalam pelatihan model CNN berbasis citra (Rosalina et al., 2025).

Arsitektur Model CNN (MobileNetV2)

Berbeda dengan model CNN konvensional yang membangun lapisan dari awal, penelitian ini menggunakan Transfer Learning pada arsitektur MobileNetV2. Model ini memanfaatkan pre-trained weights dari dataset ImageNet untuk mengenali fitur dasar citra. Arsitektur MobileNetV2 menggunakan struktur Inverted Residuals dan Linear Bottlenecks yang memungkinkan ekstraksi fitur tekstur secara lebih mendalam.

Penerapan metode ini merupakan solusi atas kendala klasifikasi pada fase kematangan yang memiliki kemiripan visual tinggi (matang dan terlalu matang), yang sering menjadi kelemahan pada penelitian terdahulu. Pada bagian akhir, lapisan *Global Average Pooling* digunakan untuk mereduksi dimensi, diikuti oleh lapisan *Dropout* (0.3) untuk mencegah *overfitting*, dan lapisan *Fully Connected* dengan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi tiga kelas.

Pelatihan Model

Proses pelatihan model dilakukan menggunakan algoritma optimasi Adam dengan fungsi kerugian *categorical cross-entropy*, yang sesuai untuk permasalahan klasifikasi multikelas. Model dilatih menggunakan data latih selama 10 *epoch*, sementara data validasi digunakan untuk memantau performa model selama proses pelatihan dan mencegah terjadinya *overfitting*.

Parameter pelatihan dipilih dengan mempertimbangkan keseimbangan antara performa model dan efisiensi komputasi, mengingat MobileNetV2 dirancang untuk menghasilkan performa yang baik dengan beban komputasi yang relatif ringan.


Evaluasi Model

Evaluasi kinerja model dilakukan menggunakan data uji yang tidak terlibat dalam proses pelatihan. Kinerja model diukur menggunakan beberapa metrik evaluasi, yaitu akurasi, *precision*, *recall*, dan *F1-score*, serta *confusion matrix* untuk mengetahui kemampuan model dalam mengklasifikasikan masing-masing kelas tingkat kematangan buah tomat secara lebih rinci (Ayunda et al., 2023).

Alur Penelitian

Secara keseluruhan, alur penelitian ini dirancang secara sistematis guna memastikan akurasi dan validitas hasil klasifikasi. Tahapan dimulai dari pengumpulan dataset citra tomat melalui seleksi ulang, dilanjutkan dengan tahap praproses data yang meliputi

resizing dan normalisasi. Tahap berikutnya adalah perancangan model menggunakan arsitektur MobileNetV2 dengan pendekatan Transfer Learning, yang dilatih menggunakan data latih dan dipantau melalui data validasi. Akhirnya, dilakukan evaluasi mendalam pada data uji independen menggunakan metrik akurasi, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Seluruh tahapan divisualisasikan dalam diagram alur untuk memberikan pemahaman terperinci mengenai proses penelitian.



Gambar 3. Diagram Alur Penelitian


C. HASIL DAN PEMBAHASAN

Pelatihan Model


Pelatihan model dilakukan menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning* pada data latih dan data validasi. Selama proses pelatihan, performa model dipantau menggunakan metrik akurasi dan nilai *loss* untuk mengamati kemampuan model dalam mempelajari pola visual dari citra buah tomat. Hasil pelatihan menunjukkan bahwa model mampu mencapai kondisi pembelajaran yang stabil, ditandai dengan peningkatan akurasi yang

konsisten serta penurunan nilai *loss* pada data latih dan validasi.

Grafik hubungan antara jumlah *epoch* terhadap nilai akurasi menunjukkan bahwa model secara bertahap mampu meningkatkan ketepatan klasifikasi seiring bertambahnya proses pembelajaran. Sementara itu, grafik *loss* memperlihatkan kecenderungan penurunan nilai kesalahan prediksi, yang mengindikasikan bahwa model berhasil menyesuaikan bobot-bobot jaringan untuk meminimalkan kesalahan klasifikasi. Pola ini menunjukkan bahwa proses pelatihan berjalan secara optimal dan tidak menunjukkan gejala *overfitting* yang signifikan. Hasil ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa penggunaan *transfer learning* pada arsitektur CNN dapat meningkatkan stabilitas dan efisiensi pelatihan model, khususnya pada dataset citra pertanian (Mutahar et al., 2024).



Gambar 4. Grafik *Accuracy vs Epoch*




Gambar 5. Grafik *Loss vs Epoch*

Training Epoch

Analisis proses pelatihan berdasarkan *epoch* dilakukan untuk memahami dinamika pembelajaran model CNN secara lebih mendalam. Setiap *epoch* merepresentasikan satu siklus pembelajaran penuh terhadap seluruh data latih, di mana parameter model diperbarui untuk memperkecil kesalahan prediksi. Pada beberapa *epoch* awal, peningkatan akurasi terjadi cukup signifikan, yang menunjukkan bahwa model mulai mengenali fitur-fitur visual utama dari citra tomat, terutama perbedaan warna dan tekstur pada masing-masing tingkat kematangan.

Seiring bertambahnya jumlah *epoch*, peningkatan akurasi menjadi lebih lambat dan cenderung stabil. Kondisi ini mengindikasikan bahwa model telah mencapai fase konvergensi, di mana penambahan *epoch* tidak lagi memberikan peningkatan performa yang berarti. Pemilihan jumlah *epoch* yang digunakan dalam penelitian ini dinilai cukup untuk mencapai keseimbangan antara performa model dan efisiensi waktu pelatihan. Pendekatan ini sesuai dengan praktik umum dalam pelatihan CNN berbasis *transfer learning*, di mana jumlah *epoch* yang terlalu besar berpotensi menyebabkan pembelajaran yang tidak efisien (Sholihin & Sunyoto, 2025).

Pemilihan jumlah *epoch* sebanyak 10 dilakukan untuk memastikan bahwa model memiliki waktu pelatihan yang cukup tanpa menyebabkan *overfitting*. Berdasarkan hasil pengamatan, jumlah *epoch* tersebut dinilai mampu menghasilkan performa yang optimal dengan waktu pelatihan yang efisien.



Gambar 6. Training epoch

Evaluasi Model

Setelah proses pelatihan selesai, model dievaluasi menggunakan data uji yang tidak terlibat dalam proses pelatihan maupun validasi. Evaluasi ini bertujuan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan citra tomat yang baru. Hasil evaluasi menunjukkan bahwa model MobileNetV2 mampu menghasilkan performa klasifikasi yang baik pada data uji, dengan nilai akurasi, presisi, *recall*, dan *F1-score* yang konsisten.

Evaluasi model dilakukan menggunakan data uji yang terdiri dari sekitar 80 citra tomat, sehingga hasil yang diperoleh mencerminkan kemampuan model dalam mengklasifikasikan data baru secara konsisten.

Konsistensi performa antara data latih, validasi, dan data uji menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak hanya menghafal pola pada data pelatihan. Hal ini menegaskan bahwa penggunaan *transfer learning* pada arsitektur MobileNetV2 mampu meningkatkan efektivitas klasifikasi citra, sebagaimana juga dilaporkan dalam penelitian klasifikasi citra pertanian sebelumnya (Appe et al., 2023; Mutahar et al., 2024).

	precision	recall	f1-score	support
matang	0.95	1.00	0.97	36
terlalu_matang	1.00	0.89	0.94	9
tidak_matang	1.00	0.97	0.99	40
accuracy			0.98	85
macro avg	0.98	0.95	0.97	85
weighted avg	0.98	0.98	0.98	85


Gambar 7. Evaluasi Model

Confusion matrix

Untuk memperoleh gambaran performa klasifikasi yang lebih rinci pada setiap kelas, digunakan *confusion matrix*. *Confusion matrix* memberikan informasi mengenai jumlah citra yang berhasil diklasifikasikan dengan benar serta citra yang mengalami kesalahan klasifikasi pada masing-masing kelas tingkat kematangan. Berdasarkan hasil

confusion matrix, model menunjukkan kemampuan klasifikasi yang baik pada ketiga kelas kematangan tomat.

Sebagian besar citra berhasil diprediksi sesuai dengan kelas aslinya, yang menunjukkan bahwa fitur visual yang diekstraksi oleh MobileNetV2 cukup representatif dalam membedakan tingkat kematangan buah tomat. Penggunaan *confusion matrix* sebagai alat evaluasi dinilai penting karena mampu mengungkap pola kesalahan klasifikasi secara spesifik pada tiap kelas, sehingga memberikan pemahaman yang lebih mendalam terhadap performa model (Appe et al., 2023).



Gambar 8. *Confusion matrix*

Hasil Klasifikasi

Pengujian model juga dilakukan secara visual dengan memasukkan citra tomat secara individual untuk melihat hasil prediksi kelas kematangan. Hasil pengujian menunjukkan bahwa model mampu mengklasifikasikan citra tomat ke dalam kelas tidak matang, matang, dan terlalu matang sesuai dengan karakteristik visual masing-masing kelas. Model memberikan hasil prediksi disertai tingkat keyakinan (*confidence score*), yang menunjukkan probabilitas keanggotaan citra terhadap kelas tertentu.

Contoh hasil klasifikasi menunjukkan bahwa model mampu mengenali perbedaan warna dan tekstur tomat secara efektif. Hal ini menegaskan bahwa kombinasi fitur warna RGB dan ekstraksi fitur otomatis oleh CNN berperan penting dalam menentukan tingkat

kematangan buah tomat. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa CNN efektif dalam memanfaatkan informasi visual untuk klasifikasi tingkat kematangan buah (Ayunda et al., 2023)

Hasil Prediksi: tidak_matang
Keyakinan: 99.92%



Gambar 9. Contoh hasil tidak matang

Hasil Prediksi: matang
Keyakinan: 99.88%



Gambar 10. Contoh hasil matang

Hasil Prediksi: terlalu_matang
Keyakinan: 95.82%



Gambar 11. Contoh hasil terlalu matang

Pembahasan

Hasil penelitian menunjukkan bahwa model yang dikembangkan mampu membedakan seluruh kelas tingkat kematangan buah tomat dengan baik, termasuk pada kelas matang dan terlalu matang yang memiliki karakteristik visual yang relatif berdekatan. Penggunaan arsitektur MobileNetV2 berbasis *transfer learning* memungkinkan model untuk mengekstraksi fitur citra secara lebih mendalam, tidak hanya berdasarkan perbedaan warna permukaan, tetapi juga variasi tekstur dan distribusi intensitas piksel yang muncul pada masing-masing tingkat kematangan.

Hal ini tercermin dari hasil evaluasi model yang menunjukkan tingkat ketepatan klasifikasi yang stabil pada seluruh kelas. Dengan demikian, pendekatan yang digunakan dalam penelitian ini mampu meminimalkan ambiguitas visual antar kelas kematangan tomat, sehingga menghasilkan sistem klasifikasi yang andal dan konsisten untuk digunakan pada data citra tomat yang beragam.

Secara keseluruhan, hasil yang diperoleh menunjukkan bahwa model CNN berbasis MobileNetV2 berbasis *transfer learning* yang digunakan memiliki performa yang baik dan berpotensi untuk diterapkan dalam sistem otomatis penentuan tingkat kematangan buah tomat berbasis pengolahan citra digital.

Penyimpanan Model CNN

Setelah seluruh tahapan pelatihan dan evaluasi selesai, model CNN yang telah dilatih disimpan dalam bentuk file model. Penyimpanan model bertujuan untuk memungkinkan penggunaan kembali model tanpa perlu melakukan proses pelatihan ulang, sehingga dapat digunakan secara langsung pada tahap pengujian lanjutan maupun implementasi sistem klasifikasi tingkat kematangan buah tomat. Langkah ini penting dalam pengembangan sistem berbasis *deep learning* karena meningkatkan efisiensi penggunaan model dalam aplikasi nyata.

D. PENUTUP

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 berbasis *transfer learning* mampu mengklasifikasikan tingkat kematangan buah tomat secara efektif dan konsisten. Seluruh tahapan penelitian, mulai dari pengolahan dataset, praproses citra, pelatihan model, hingga evaluasi, menunjukkan bahwa model yang dibangun mampu mengenali perbedaan karakteristik visual pada masing-masing tingkat kematangan buah tomat dengan baik.

Hasil evaluasi model menunjukkan performa klasifikasi yang stabil pada ketiga kelas, yaitu tidak matang, matang, dan terlalu matang. Model mampu mengekstraksi fitur citra secara optimal sehingga proses klasifikasi berjalan dengan lancar tanpa indikasi kesalahan klasifikasi yang signifikan antar kelas. Hal ini menunjukkan bahwa arsitektur MobileNetV2 memiliki kemampuan yang baik dalam memanfaatkan informasi warna dan tekstur citra tomat untuk mendukung proses pengambilan keputusan klasifikasi.

Selain itu, penggunaan pendekatan *transfer learning* terbukti meningkatkan efisiensi pelatihan model serta menghasilkan performa yang konsisten pada data uji. Dengan demikian, sistem klasifikasi tingkat kematangan buah tomat yang dikembangkan dalam penelitian ini dinilai andal dan berpotensi untuk diterapkan pada sistem otomatis berbasis pengolahan citra digital di bidang pertanian dan pascapanen.

Meskipun penelitian ini telah menunjukkan hasil yang baik, terdapat beberapa hal yang dapat dikembangkan pada penelitian selanjutnya. Pertama, jumlah dan variasi dataset citra tomat dapat diperluas, khususnya dengan mempertimbangkan variasi kondisi pencahayaan dan sudut pengambilan gambar, agar model memiliki kemampuan generalisasi yang lebih tinggi.

Kedua, penelitian selanjutnya dapat mengeksplorasi teknik *fine-tuning* pada lapisan tertentu dari MobileNetV2 untuk melihat potensi peningkatan performa klasifikasi. Selain itu, pengembangan sistem klasifikasi dalam bentuk aplikasi atau sistem berbasis perangkat bergerak dapat menjadi langkah lanjutan untuk mendukung implementasi model secara langsung di lapangan.

E. DAFTAR PUSTAKA

- Appe, S. R. N., Arulselvi, G., & Balaji, G. N. (2023). Tomato Ripeness Detection and Classification using VGG based CNN Models. *IJISAE : International Journal of Intelligent Systems and Applications in Engineering*, 11(1), 296–302. <https://www.ijisae.org/index.php/IJISAE/article/view/2538>
- Ayunda, N. A., Haryatmi, E., & Riyadi, T. A. (2023). Classification of Tomato Ripeness Based on Convolutional Neural Network Methods. *Journal of Information Systems and Informatics*, 5(4), 1658–1675. <https://doi.org/10.51519/journalisi.v5i4.613>
- Choirunisa, S., & Supatman. (2025). Klasifikasi Tingkat Kematangan Citra Buah Tomat Menggunakan Densenet-121. *JITET: Jurnal Informatika Dan Teknik Elektro Terapan*, 13(3), 1998–2003. <https://doi.org/10.23960/jitet.v13i3.6652>
- Fajar, M., Sulthan, M. B., & Wahyudi, I. (2023). Klasifikasi Tingkat Kematangan Buah Tomat Menggunakan Fitur Rgb Dan Hsi Berbasis Backpropagation. *JATIM: Jurnal Aplikasi Teknologi Informasi Dan Manajemen*, 4(1), 84–95. <https://doi.org/10.31102/jatim.v4i1.2177>
- Husna, M., & Fatah, Z. (2026). Klasifikasi Kematangan Tanaman Buah Tomat Menggunakan Teachable Machine: Pendekatan Berbasis Gambar. *JAMASTIKA : Jurnal Mahasiswa Teknik Informatika*, 5(1), 92–97. <https://doi.org/10.35473/jamastika.v5i1.4599>
- Mardianto, Y., Dewi, T., & Risma, P. (2024). Analisis Klasifikasi Kematangan Buah Tomat dengan Pendekatan Transfer Learning Model EfficientNet. *Techno Bahari*, 11(1), 20–25. <https://doi.org/10.52234/tb.v11i1.306>
- Mutahar, M., Kannan, S., Jafer, M. M., & Ragavendra K, M. (2024). Deep Learning-Based Tomato Ripeness Detection: A ResNet-152 Approach. *IJSRST: International Journal of Scientific Research in Science and Technology*, 11(1), 34–41. <https://doi.org/10.32628/IJSRST5241113>
- Rosalina, Husodo, A. Y., & Wijaya, I. G. P. S. (2025). Development of a Convolutional Neural Network Method for Classifying Ripeness Levels of Servo Variety Tomatoes. *JUTIF : Jurnal Teknik Informatika*, 6(2), 501–520. <https://doi.org/10.52436/1.jutif.2025.6.2.4168>
- Rumbekwan, J. I. W., & Aryanto, J. (2025). Application of Convolutional Neural Networks for Tomato Fruit Ripeness Identification. *JSRET: Journal of Scientific Research, Education, and Technology*, 4(1), 61–78. <https://doi.org/10.58526/jsret.v4i1.645>
- Samual, M. A., & Wijanarko, S. (2026). Comparative Analysis of CNN and Random Forest for Cashew Plant Disease Classification. *Sistemasi: Jurnal Sistem Informasi*, 15(3), 961–970. <https://doi.org/10.32520/stmsi.v15i3.6100>
- Santoso, K. A., Kamsyakawuni, A., & Izza, S. V. R. (2024). Comparison Classification Of Tomatoes Ripeness

Based On RGB, HSV And CMYK Colors Based On Correlation Coefficient. *Journal of Computers and Digital Business*, 3(3), 112–120. <https://doi.org/10.56427/jcbd.v3i3.410>

Saparudin, H., Ramdi, M. A., & Alfarizi, F. S. (2025). Implementasi Convolutional Neural Network dan ResNet-18 untuk Klasifikasi Kerusakan Jalan Berbasis Citra. *JAPTIKA: Jurnal Aplikasi Informatika Dan Multimedia*, 1(1), 27–31. <https://doi.org/10.64878/japtika.v1i1.53>

Sholihin, I., & Sunyoto, A. (2025). Improving Tomato Ripeness Classification Using Knowledge Distillation and Hyperparameter Optimization with Optuna. *Jeecom : Journal of Electrical Engineering and Computer*, 7(2), 282–290. <https://doi.org/10.33650/jeecom.v7i2.11266>