

Penerapan Transfer Learning *MobileNetV2* Pada Klasifikasi Citra Jenis Buah-Buahan

Applying MobileNetV2 Transfer Learning for Image Classification of Fruit Types

Antony Christ Hartono*, Ahmad Rofiqul Muslikh

Sistem Informasi, Fakultas Teknologi Informasi, Universitas Merdeka Malang, Malang, Indonesia

E-mail: *hartono.antony@student.unmer.ac.id

Abstract. The development of technology in the field of Deep Learning using the CNN method is capable of automatically extracting features and accurately classifying them. The purpose of this research is to overcome training limitations from the beginning (bottom-up) by using Transfer Learning with a customized MobileNetV2 architecture. Additionally, they evaluated its performance using the metrics of accuracy, precision, recall, and F1 score. The dataset was obtained by scraping and manually selecting images from various public sources using Kaggle. This resulted in 4000 images from twenty fruit classes. The modeling was done in the Google Colab environment using the Python programming language and utilizing libraries such as TensorFlow, Keras, and Scikit-learn, among others, as support. The research results show that the model has 94% accuracy on test data, with average accuracy, recall, and F1 scores of 0.93–0.94, and perfect performance of 1.00 in several classes. This indicates that MobileNetV2 performs well in fruit image classification due to the limited amount of data, relatively short training time, and computational resource efficiency.

Keywords: Artificial Intelligence; Deep Learning; CNN; Transfer Learning MobileNetV2

Abstrak. Perkembangan teknologi pada bidang *Deep Learning* dengan metode *CNN* mampu melakukan ekstraksi fitur secara otomatis dan klasifikasi secara akurat. Tujuan dari penelitian ini adalah untuk mengatasi keterbatasan pelatihan dari awal (dari bawah ke atas) dengan menggunakan Transfer Learning dengan arsitektur *MobileNetV2* yang disesuaikan. Selain itu, mereka mengevaluasi performanya dengan menggunakan metrik ketepatan, ketepatan, *recall*, dan skor *f1*. Dataset berasal dari *scraping* dan pemilahan manual dari berbagai sumber publik menggunakan *Kaggle*. Ini menghasilkan 4000 gambar dari dua puluh kelas buah. Pemodelan dilakukan di lingkungan *Google Colab* menggunakan bahasa pemrograman *Python* dan menggunakan pustaka seperti *TensorFlow*, *Keras*, dan *Scikit-learn*, antara lain, sebagai pendukung. Hasil penelitian menunjukkan bahwa model memiliki ketepatan 94% pada data uji, dengan skor ketepatan, *recall*, dan *f1* rata-rata 0.93–0.94, dan performa sempurna 1.00 pada beberapa kelas. Hal ini menunjukkan bahwa *MobileNetV2* bekerja dengan baik dalam klasifikasi gambar buah-buahan karena jumlah data yang terbatas, waktu pelatihan yang relatif singkat, dan efisiensi sumber daya komputasi.

Kata kunci: Artificial Intelligence; Deep Learning; CNN; Transfer Learning MobileNetV2

Submitted: 16-09-2025 | Accepted: 25-09-2025 | Published: 30-09-2025

How to Cite:

A.C. Hartono and A.R. Muslikh, " Penerapan Transfer Learning MobileNetV2 Pada Klasifikasi Citra Jenis Buah-Buahan," *Journal of Information System and Application Development (JISAD)*, vol. 3, no. 2, pp. 102-110, 2025, doi: 10.26905/jisad.v3i2.16187.



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.
DOI: [10.26905/jisad.v3i2.16187](https://doi.org/10.26905/jisad.v3i2.16187)

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan atau *Artificial Intelligence* (AI) telah mengalami akselerasi yang signifikan dalam beberapa tahun terakhir. AI sendiri merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem atau mesin yang mampu melakukan berbagai tugas yang biasanya. Hal ini memerlukan kecerdasan manusia, seperti pengenalan pola, pemecahan masalah, pembelajaran, dan pengambilan keputusan [1]. Salah satu cabang AI yang berperan besar adalah *Deep Learning*, terutama dalam pengolahan citra digital karena mampu mempelajari pola secara langsung dari data tanpa instruksi eksplisit sehingga lebih adaptif terhadap kebutuhan dunia nyata [2].

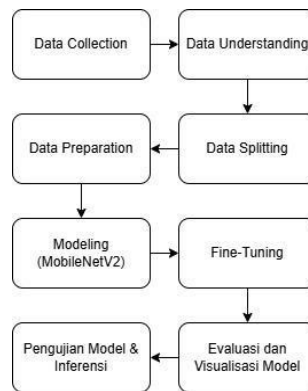
Salah satu pendekatan yang banyak digunakan dalam menyelesaikan permasalahan klasifikasi gambar adalah *Convolutional Neural Network* (CNN). CNN mampu menerima *input* berupa gambar, mengekstraksi fitur penting, dan membedakan antara satu gambar dengan yang lainnya [3]. Berbagai penelitian telah membuktikan keunggulan CNN dalam klasifikasi citra buah dengan akurasi yang lebih tinggi dibandingkan metode konvensional. Penelitian oleh Putra berhasil melakukan klasifikasi jenis buah dengan rata-rata akurasi mencapai 90% [4]. Penelitian lain oleh Paraijun et al mengembangkan model klasifikasi kesegaran buah dan memperoleh akurasi sebesar 93% [5]. Sementara itu, penelitian oleh Rahayu et al menunjukkan akurasi sebesar 96% menggunakan CNN untuk klasifikasi jenis buah [6]. Hasil tersebut menunjukkan potensi besar CNN, meskipun masih terdapat ruang pengembangan. Misalnya melalui penggunaan data set yang lebih bervariasi, penerapan teknik data *augmentation* lebih lanjut, serta pemanfaatan *pretrained* model atau arsitektur yang lebih efisien.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi citra jenis buah-buahan dengan arsitektur CNN. Klasifikasi ini melakukan pendekatan *Transfer Learning*, yaitu metode dalam *Machine Learning* yang memanfaatkan pengetahuan dari model yang telah lebih dulu dilatih pada tugas atau data set serupa untuk meningkatkan kinerja pada permasalahan baru [7]. Metode *Transfer Learning* yang digunakan dalam penelitian ini adalah *MobileNetV2*, sebuah arsitektur yang dirancang untuk menghadirkan model yang ringan dan efisien secara komputasi. Sehingga cocok diterapkan pada perangkat dengan keterbatasan sumber daya, seperti *mobile* maupun sistem *edge computing* [8].

Penelitian ini difokuskan pada evaluasi efisiensi dan performa model dengan menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*, yang dipilih. Hal ini mampu memberikan gambaran menyeluruh mengenai kemampuan model dalam mengenali kelas dengan benar, mengukur ketepatan prediksi, serta menilai keseimbangan performa antar kelas. Selain memberikan kontribusi teoritis terhadap pengembangan CNN dan *Transfer Learning* dalam klasifikasi citra digital. Penelitian ini juga memiliki manfaat praktis bagi sektor pertanian digital melalui sistem klasifikasi buah otomatis yang dapat mempercepat proses pemilihan buah pasca panen.

METODE

Penelitian ini masuk dalam kategori penelitian kuantitatif eksperimental. Penelitian ini bertujuan untuk menguji efektivitas arsitektur CNN dengan pendekatan *Transfer Learning* menggunakan *MobileNetV2* dalam melakukan klasifikasi citra jenis buah-buahan. Metode kuantitatif eksperimental digunakan karena penelitian ini melibatkan proses pelatihan model. Pengujian performa serta evaluasi model dengan metrik seperti *accuracy*, *precision*, *recall*, dan *f1-score*. Langkah-langkah penelitian yang akan dilakukan meliputi pengumpulan data, memahami data (data understanding), pembagian data (data *splitting*), persiapan data, modeling menggunakan *MobileNetV2*, *fine-tuning*, evaluasi model, visualisasi model, dan pengujian model serta interfensi sederhana.



Gambar 1. Alur Tahapan Penelitian

Gambar 1 menunjukkan tahap penelitian dimulai dari pengumpulan data yang merupakan fondasi utama dalam membangun sistem klasifikasi citra. Data yang digunakan merupakan data set citra buah yang diperoleh dari sumber publik *Kaggle*. Setelah data terkumpul, langkah berikutnya adalah data *understanding*, yaitu proses pemahaman terhadap karakteristik dataset secara menyeluruh. Tahap ini mencakup analisis struktur dan komposisi data citra buah, identifikasi jumlah kelas beserta distribusinya, serta pemeriksaan potensi permasalahan seperti ketidak seimbangan kelas, kualitas citra yang bervariasi, atau adanya data yang *corrupt*.

Setelah memahami karakteristik dataset, tahap selanjutnya adalah data *splitting* atau pemisahan data. Proses ini bertujuan membagi dataset menjadi tiga subset, yaitu data pelatihan (*training set*), data validasi (*validation set*), dan data pengujian (*testing set*). Pembagian ini penting untuk memastikan model dapat dilatih secara optimal, divalidasi untuk mencegah *overfitting*, yaitu kondisi ketika model belajar terlalu baik pada data pelatihan hingga kehilangan kemampuan generalisasi terhadap data baru [9]. Selanjutnya, data citra akan diproses melalui beberapa tahapan mulai dari penetapan parameter dasar seperti ukuran citra dan *batch size*, serta pembentukan data *loader* untuk subset pelatihan, validasi, dan pengujian.

Tahap-tahap ini memastikan citra diproses secara konsisten dan efisien untuk model CNN berbasis *MobileNetV2* termasuk normalisasi (*resizing* ke 224x224 piksel) hal ini penting dalam meningkatkan kualitas representasi input model [10]. Untuk menangani keterbatasan jumlah data dan meningkatkan daya *robust* model terhadap berbagai variasi citra, diterapkan teknik data *augmentation*, yaitu proses memperluas dataset latih dengan memodifikasi data yang sudah ada sehingga keragaman data meningkat dan model lebih mampu melakukan generalisasi [11]. Teknik data *augmentation* yang digunakan mencakup transformasi seperti *flipping*, *rotation*, *translation*, *zoom*, *brightness adjustment*, *shearing*, serta *fill mode* untuk menutupi area kosong pasca transformasi. Kemudian, proses data *loader* digunakan untuk memastikan gambar dapat dimuat, diproses, dan dikelompokkan ke dalam *batch* dengan benar sebelum masuk ke model. Proses ini membantu mempercepat pelatihan serta membuat model lebih cepat mencapai hasil yang baik dalam klasifikasi [12].

Pada penelitian ini, pemodelan dilakukan dengan menggunakan arsitektur CNN *pretrained MobileNetV2* melalui pendekatan *Transfer Learning*. *MobileNetV2* telah dilatih pada dataset besar sehingga mampu mengenali fitur visual dasar seperti tepi, tekstur, dan bentuk, serta membekali model dengan kemampuan yang kuat meskipun data latih terbatas [13]. Lapisan klasifikasi bawaan *MobileNetV2* diganti dengan lapisan baru yang disesuaikan dengan jumlah kelas pada dataset. Modifikasi ini mencakup penambahan *fully connected layer*, yaitu lapisan yang umumnya terletak pada bagian akhir dan memiliki koneksi penuh dengan seluruh *neuron* pada lapisan sebelumnya [14].

Modifikasi lainnya adalah lapisan output dengan aktivasi *softmax* untuk mendukung klasifikasi multi kelas. Selain itu, lapisan dropout disisipkan untuk meningkatkan generalisasi dan mengurangi risiko *overfitting*. Model kemudian dikompilasi menggunakan Adam *optimizer*, *categorical cross-entropy*

sebagai fungsi *loss*, serta *accuracy* sebagai metrik evaluasi.

Tahap berikutnya adalah *fine-tuning*, yaitu proses penyesuaian bobot pada beberapa lapisan atas *MobileNetV2* serta lapisan klasifikasi baru agar lebih adaptif terhadap karakteristik citra buah. Lapisan awal yang mengekstraksi fitur dasar dibekukan (*frozen*). Sementara lapisan konvolusi akhir dan lapisan dense yang baru ditambahkan dilatih ulang agar dapat mengenali pola spesifik dari citra buah. Strategi ini telah terbukti efektif dalam meningkatkan akurasi klasifikasi menggunakan *Transfer Learning MobileNetV2*, khususnya pada dataset terbatas [15]. Proses pelatihan dilakukan menggunakan *training set* dan *validation set*, disertai mekanisme callback seperti *ModelCheckpoint* dan *Early Stopping*.

Model Checkpoint memastikan model menyimpan *checkpoint* dengan performa validasi terbaik. Sedangkan *Early Stopping* menghentikan pelatihan jika tidak ditemukan peningkatan signifikan pada metrik validasi. Sehingga efisiensi komputasi tetap terjaga dan risiko *overfitting* dapat diminimalkan [16]. Melalui kombinasi pendekatan *Transfer Learning* dan *fine-tuning* yang terencana, model diharapkan mampu mencapai akurasi tinggi sekaligus mempertahankan kemampuan generalisasi yang baik dalam klasifikasi jenis buah-buahan.

Tahap evaluasi dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan citra buah pada data yang belum pernah digunakan sebelumnya. Proses ini bertujuan untuk menilai sejauh mana model mampu melakukan generalisasi terhadap data baru. Evaluasi dilakukan secara sistematis menggunakan *testing set* yang telah dipisahkan pada tahap awal. Beberapa metrik yang digunakan meliputi *accuracy*, *confusion matrix*, dan *classification report*. *Accuracy* digunakan untuk mengetahui proporsi prediksi yang benar dari keseluruhan data. Sehingga memberikan gambaran umum mengenai kinerja model.

Confusion matrix divisualisasikan untuk menampilkan distribusi hasil klasifikasi, termasuk jumlah *true positive*, *true negative*, *false positive*, dan *false negative* pada setiap kelas buah. Selanjutnya, berdasarkan *confusion matrix* dihitung metrik lain berupa *precision*, *recall*, dan *f1-score* yang dirangkum dalam *classification report*. Kombinasi metrik ini penting untuk memberikan pemahaman yang lebih rinci mengenai keunggulan dan keterbatasan model, termasuk identifikasi kelas yang sering salah diklasifikasikan serta kesalahan Tipe I dan Tipe II.


Setelah tahap evaluasi, dilakukan pengujian lebih lanjut melalui proses inferensi untuk memverifikasi kemampuan model pada citra buah yang benar-benar baru. Pada tahap ini, model yang telah dioptimalkan diberikan *input* berupa citra uji. Kemudian diproses melalui lapisan-lapisan jaringan hingga menghasilkan prediksi kelas. *Output* model berupa probabilitas untuk setiap kategori buah, dengan kelas berprobabilitas tertinggi ditetapkan sebagai hasil klasifikasi. Pengujian dan inferensi ini bertujuan untuk menilai efektivitas model CNN berbasis *pretrained MobileNetV2* dalam mengenali jenis buah pada kondisi nyata. Hasilnya memberikan validasi akhir mengenai kesiapan model untuk diterapkan pada aplikasi dunia nyata, khususnya dalam sistem klasifikasi otomatis berbasis citra buah.

HASIL DAN PEMBAHASAN

Model klasifikasi citra jenis buah yang dibangun dengan arsitektur *MobileNetV2* dan strategi *fine-tuning* menunjukkan performa yang sangat baik. Hasil pengujian memperlihatkan bahwa akurasi pelatihan mencapai 98,25%, akurasi validasi sebesar 95,50%, serta akurasi pada *test set* sebesar 93,50%. Hasil evaluasi ini menunjukkan bahwa model mencapai akurasi yang sangat tinggi pada data pelatihan. Ini mengindikasikan bahwa model telah berhasil mempelajari pola-pola dalam dataset citra jenis buah-buahan. Akurasi validasi sebesar 95.50% menunjukkan kemampuan model yang baik dalam melakukan generalisasi pada data yang tidak digunakan untuk pelatihan langsung. Meskipun terdapat sedikit penurunan pada akurasi *test set* menjadi 93.50%, nilai ini masih tergolong sangat baik dan menunjukkan bahwa model memiliki kemampuan generalisasi yang kuat dan dapat bekerja efektif pada data baru yang belum pernah dilihat sebelumnya.

Confusion Matrix

Untuk memperoleh pemahaman yang lebih mendalam terhadap kinerja model klasifikasi dalam mengamati distribusi prediksi yang benar maupun yang salah pada setiap kelas. Peneliti telah membangun kode untuk memvisualisasikan *confusion matrix*. *Confusion matrix* adalah tabel yang menggambarkan performa model klasifikasi pada data test. Visualisasi ini membantu dalam mengidentifikasi kelas-kelas yang sering mengalami kesalahan klasifikasi serta membantu memahami pola kesalahan yang terjadi selama proses prediksi.



Gambar 2. Visualisasi *Confusion Matrix*

Gambar 2 menunjukkan performa model klasifikasi dalam membedakan 20 jenis buah berdasarkan data uji. Setiap baris merepresentasikan label sebenarnya (*true label*) sedangkan setiap kolom menunjukkan label yang diprediksi oleh model (*predicted model*). Nilai yang tinggi pada diagonal utama menandakan jumlah prediksi yang benar untuk masing-masing kelas sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Berdasarkan hasil visualisasi di atas berikut adalah hasil interpretasi *confusion matrix* yang disajikan dalam bentuk tabel 1.

Tabel 1. Interpretasi *Confusion Matrix*

No	Kelas	Jumlah Sampel	Prediksi Benar	Prediksi Salah	Akurasi per Kelas
1	Apple	20	19	1	95%
2	Avocado	20	16	4	80%
3	Banana	20	19	1	95%
4	Carrot	20	20	0	100%
5	Dragonfruit	20	19	1	95%
6	Durian	20	20	0	100%
7	Grapes	20	15	5	75%
8	Guanabana	20	20	0	100%
9	Guava	20	18	2	90%
10	Lychee	20	20	0	100%
11	Mango	20	15	5	75%
12	Melon	20	20	0	100%
13	Orange	20	20	0	100%
14	Papaya	20	18	2	90%
15	Pineapple	20	20	0	100%
16	Rambutan	20	20	0	100%

17	Salak	20	19	1	95%
18	Strawberry	20	19	1	95%
19	Tomato	20	20	0	100%
20	Watermelon	20	17	3	85%

Dari hasil *confusion matrix* ini, dapat disimpulkan bahwa meskipun secara keseluruhan model bekerja dengan sangat baik, masih terdapat beberapa kelas yang cenderung sulit dibedakan. Ini dikarenakan adanya kesamaan fitur visual antar buah sehingga memerlukan teknik augmentasi tambahan dan juga peningkatan kualitas data pelatihan.

Classification Report

Untuk mengevaluasi performa model lebih *detail* terhadap masing-masing kelas. Peneliti menggunakan *classification report* untuk memberikan ringkasan metrik evaluasi, seperti *precision*, *recall*, dan *f1-score* secara individual untuk setiap kelas. Selain itu, juga terdapat *support* atau jumlah sampel sebenarnya pada data uji. Laporan ini berguna untuk evaluasi yang lebih terukur mengenai kemampuan model dalam membedakan setiap kategori buah dan mengetahui lebih dalam tentang sejauh mana model mampu mengklasifikasikan masing-masing jenis buah dengan baik. Hasil *classification report* dari model yang telah dibangun dapat dilihat pada tabel 2.

Tabel 2. Hasil *Classification Report*

	<i>precision</i>	<i>recall</i>	<i>f1-score</i>	<i>support</i>
<i>Apple</i>	0.90	0.95	0.93	20
<i>Avocado</i>	0.94	0.80	0.86	20
<i>Banana</i>	1.00	0.95	0.97	20
<i>Carrot</i>	0.95	1.00	0.98	20
<i>Dragonfruit</i>	0.95	0.95	0.95	20
<i>Durian</i>	1.00	1.00	1.00	20
<i>Grapes</i>	1.00	0.75	0.86	20
<i>Guanabana</i>	0.87	1.00	0.93	20
<i>Guava</i>	0.90	0.90	0.90	20
<i>Lychee</i>	0.95	1.00	0.98	20
<i>Mango</i>	0.79	0.75	0.77	20
<i>Melon</i>	0.91	1.00	0.95	20
<i>Orange</i>	0.91	1.00	0.95	20
<i>Papaya</i>	0.82	0.90	0.86	20
<i>Pineapple</i>	1.00	1.00	1.00	20
<i>Rambutan</i>	1.00	1.00	1.00	20
<i>Salak</i>	1.00	0.95	0.97	20
<i>Strawberry</i>	1.00	0.95	0.97	20
<i>Tomato</i>	0.91	1.00	0.95	20
<i>Watermelon</i>	0.94	0.85	0.89	20
<i>accuracy</i>			0.94	400
<i>macro avg</i>	0.94	0.93	0.93	400
<i>weighted avg</i>	0.94	0.94	0.93	400

Secara keseluruhan model menunjukkan performa yang sangat baik dengan akurasi total sebesar 94% serta nilai rata-rata *macro avg* dan *weighted avg* yang konsisten, yaitu dengan *precision* 0.94, *recall* 0.93 – 0.94, dan *f1-score* 0.93. Hal ini menunjukkan bahwa model memiliki kemampuan yang seimbang dalam mengenali kelas-kelas dengan jumlah sampel yang merata. Beberapa kelas menunjukkan hasil yang sempurna, seperti durian, *pineapple*, dan rambutan, dengan nilai *precision*, *recall*, dan *f1-score* sebesar 1.00 yang berarti semua gambar dalam kelas tersebut diklasifikasikan

dengan benar tanpa kesalahan. Selain itu beberapa kelas juga memiliki nilai *precision*, *recall*, dan *f1-score* yang relatif tinggi berkisar antara 0.90-0.98.

Namun demikian, terdapat beberapa kelas yang menunjukkan performa relatif rendah seperti, *mango* hanya memperoleh *precision* sebesar 0.79, *recall* 0.75, dan *f1-score* 0.77. Ini mengindikasikan bahwa model cukup sering melakukan kesalahan saat mengklasifikasikan buah ini. *Grapes* juga memiliki *recall* yang cukup rendah yaitu sebesar 0.75, meskipun nilai *precision* tinggi 1.00. Ini menunjukkan bahwa model cukup selektif dalam memprediksi kelas ini namun sering gagal dalam mengenali semua gambar yang sebenarnya adalah *grapes*. *Avocado*, *papaya*, dan *watermelon* juga memiliki nilai yang rendah dari hasil *classification report*. Ini juga menunjukkan bahwa model masih melakukan beberapa kesalahan klasifikasi pada ketiga kelas ini.

Performa yang tidak konsisten pada beberapa kelas ini kemungkinan disebabkan oleh kemiripan visual antar kelas buah atau variasi pencahayaan dan sudut pengambilan gambar pada dataset. Oleh karena itu, hasil *classification report* ini dapat menjadi acuan dalam melakukan perbaikan pada sisi data. Misalnya seperti augmentasi tambahan, penambahan data gambar maupun peningkatan pada arsitektur model agar hasil klasifikasi lebih optimal dan konsisten pada semua kelas.

Hasil Perbandingan Model

Tabel 3. Hasil Perbandingan Model

No	Penulis	Metode	Hasil Akurasi	Jumlah Dataset dan Kelas
1.	Ilham Rizaldy Widy Putra (2020)	<i>Convolutional Neural Network</i>	Hasil akurasi rata-rata pada data uji 90%	Jumlah total dataset sebesar 90.483 dan 40 kelas citra uji
2.	Femil Paraijun, Rosida Nur Aziza, dan Dwina Kuswardani (2022)	<i>Convolutional Neural Network</i>	Hasil akurasi rata-rata pada data uji 93%	Jumlah total dataset 13.599 dan 6 kelas citra uji
3.	Dede Wulan Rahayu, David Setiadi, dan Dwi Yuniarto (2024)	<i>Convolutional Neural Network</i>	Hasil akurasi rata-rata pada data uji 100%	Jumlah total dataset 22.495 dan 23 kelas citra uji
4.	Yuwan Jumaryadi, Alif Muhammad Ihsan, dan Bagus Priambodo (2023)	<i>Convolutional Neural Network pretrained InceptionV3</i>	Hasil akurasi rata-rata pada data uji 90%	Jumlah total dataset 1.138 dan 2 kelas citra uji
5.	Pretti Nada Cahaya Irawan (2024)	<i>Convolutional Neural Network</i>	Hasil akurasi rata-rata pada data uji 75%	Jumlah total dataset 3.363 dan 20 kelas citra uji
6.	Penelitian ini (2025)	<i>Convolutional Neural Network pretrained MobileNetV2</i>	Hasil akurasi rata-rata pada data uji 94%	Jumlah total dataset 4000 dan 20 kelas citra uji

Tabel 3 menyajikan perbandingan hasil penelitian dengan beberapa penelitian terdahulu yang relevan dalam bidang klasifikasi citra menggunakan *CNN*. Perbandingan ini dilakukan untuk mengevaluasi kapabilitas metode yang diusulkan dalam mengatasi keterbatasan pelatihan model dari awal (*from scratch*) khususnya terkait kebutuhan data yang besar serta efisiensi dan performa model berdasarkan jumlah dataset dan varisi kelas.

Penelitian ini mengimplementasikan pendekatan *Transfer Learning* menggunakan arsitektur *pretrained MobileNetV2*. Pendekatan ini dipilih untuk mengatasi keterbatasan pelatihan *CNN* dari awal. Berdasarkan tabel dapat diamati bahwa penelitian terdahulu yang cenderung menggunakan pelatihan arsitektur *CNN* dasar misalnya, penelitian oleh Putra, Paraijun et al., Rahayu et al., dan

Irawan seringkali membutuhkan jumlah dataset yang besar untuk mencapai akurasi tinggi atau justru menunjukkan akurasi yang lebih rendah dengan menggunakan kelas yang lebih banyak.

Dari hasil penelitian ini penulis berhasil mencapai akurasi 94% pada data uji dengan dataset yang relatif terbatas untuk melakukan training, yaitu 4000 citra untuk 20 kelas. Hal ini menunjukkan efisiensi pendekatan *Transfer Learning* dalam mencapai performa kompetitif sekaligus mengatasi keterbatasan. Perbandingan dengan penelitian yang juga menggunakan *Transfer Learning* oleh Jumaryadi et al., menunjukkan bahwa penelitian ini, dengan dataset 4.000 citra dan 20 kelas mampu mencapai akurasi 94% sedikit lebih tinggi dari akurasi 90% yang dicapai Jumaryadi et al., yang hanya mengklasifikasikan 2 kelas dengan 1.138 citra.

Meskipun *Transfer Learning* terbukti efisien perlu diingat bahwa perancangan arsitektur model yang cocok dengan karakteristik dataset juga merupakan faktor yang dapat mempengaruhi akurasi. Selain itu menggunakan CNN dari awal maupun pendekatan *Transfer Learning*. Namun, secara garis besar perbandingan ini sudah cukup menunjukkan performa kompetitif *Transfer Learning* dalam melakukan tugas klasifikasi citra.

SIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa Transfer Learning dengan arsitektur *MobileNetV2* merupakan solusi efektif untuk klasifikasi citra 20 jenis buah. Model yang dihasilkan mencapai akurasi 94% dengan waktu pelatihan relatif singkat. Meskipun performa beberapa kelas seperti mangga dan semangka masih dapat ditingkatkan. Untuk penelitian selanjutnya, disarankan untuk memperluas variasi dataset, menerapkan augmentasi data yang lebih spesifik, dan mengeksplorasi arsitektur lain guna meningkatkan kemampuan generalisasi model serta mengembangkan aplikasinya secara nyata.

DAFTAR PUSTAKA

- [1] S. J. Russell And P. Norvig, "Artificial Intelligence: A Modern Approach, 4th Ed. Hoboken", Nj: Pearson, 2020.
- [2] R. C. Tarumingkeng, "Deep Learning". Bogor, Indonesia: Rudyct E-Press, 2024.
- [3] N. A. Batubara And R. M. Awangga, "Tutorial Object Detection Plate Number With Convolution Neural Network (Cnn)," Vol. 1. Kreatif Industri Nusantara, 2020.
- [4] I. R. W. Putra, "Deteksi Jenis Buah-Buahan Menggunakan Deep Learning," Skripsi, Fakultas Teknologi Dan Informatika, Universitas Dinamika, 2020. [Online]. Available: <https://Repository.Dinamika.Ac.Id/Id/Eprint/5392/1/17410200032-2020-Universitasdinamika.Pdf>
- [5] F. Paraijun, R. N. Aziza, And D. Kuswardani, "Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah," Kilat: Jurnal Ilmiah Teknologi Dan Informasi, Vol. 11, No. 1, Pp. 1–9, 2022. [Online]. Available: <https://doi.org/10.33322/Kilat.V11i1.1458>
- [6] D. W. Rahayu, D. Setiadi, And D. Yuniarto, "Penerapan Deep Learning Untuk Klasifikasi Buah Berdasarkan Citra Dengan Metode Convolutional Neural Networks," Indotech: Indonesian Journal Of Education And Computer Science, Vol. 2, No. 3, Pp. 196–202, 2024. [Online]. Available: <https://jurnal.intekom.id/index.php/indotech>
- [7] A. R. Muslikh, D. R. I. M. Setiadi, And A. A. Ojugo, "Rice Disease Recognition Using Transfer Learning Xception Convolutional Neural Network," Jurnal Teknik Informatika (Jutif), Vol. 4, No. 6, Pp. 1541–1547, 2023. [Online]. Available: <https://doi.org/10.52436/1.Jutif.2023.4.6.1529>
- [8] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, And L.-C. Chen, "Mobilenetv2: Inverted Residuals And Linear Bottlenecks," In Proc. 2018 Ieee/Cof Conf. Comput. Vis. Pattern Recognit. (Cvpr), 2018, Pp. 4510–4520. [Online]. Available: <https://doi.org/10.1109/Cvpr.2018.00474>

- [9] Ravi, N, Gabeur, V, & Hu, Yt 2024, 'Mobilenetv2: Inverted Residuals And Linear Bottlenecks', Arxiv
- [10] Q. Aini, N. Lutfiani, H. Kusumah, And M. S. Zahran, "Deteksi Dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo," *Cess (Journal Of Computer Engineering System And Science)*, Vol. 6, No. 2, Jul. 2021. [Online]. Available: <https://doi.org/10.24114/Cess.V6i2.25840>
- [11] A. M. Simarmata, A. Z. Putra, And A. M. Husein, "Penerapan Metode Computer Vision Dalam Klasifikasi Buah Jeruk Menggunakan Teknik Image Pre-Processing," *Dsi: Jurnal Data Science Indonesia*, Vol. 3, No. 2, 2024. [Online]. Available: <https://doi.org/110.47709/Dsi.V3i2.4010>
- [12] W. Sapitri, Y. N. Kunang, I. Z. Yadi, And M. Mahmud, "The Impact Of Data Augmentation Techniques On The Recognition Of Script Images In Deep Learning Models," *Join (Jurnal Online Informatika)*, Vol. 8, No. 2, Pp. 169–176, Dec. 2023. [Online]. Available: <https://doi.org/10.15575/Join.V8i2.1073>
- [13] M. I. Iqbal And D. Avianto, "Squeeze-And-Excitation Networks And Attention Mechanism In Automatic Detection Of Coffee Leaf Diseases Based On Images," *J. Soft Comput. Explor.*, Vol. 5, No. 4, Pp. 320–331, Dec. 2024. [Online]. Available: <https://shmpublisher.com/index.php/joscecx>
- [14] Y. A. Sitorus, Y. A. Sari, And S. Adinugroho, "Evaluasi Komparatif Arsitektur Lightweight Cnn, Mobilenetv2, Dan Efficientnetb0 Dalam Deteksi Penyakit Daun Jagung," *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, Vol. 9, No. 8, Aug. 2025. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaria, M. A. Fadhel, M. Al-Amidie, And L. Farhan, "Review Of Deep Learning: Concepts, Cnn Architectures, Challenges, Applications, Future Directions," *Journal Of Big Data*, 2021. [Online]. Available: <https://doi.org/10.1186/S40537-021-00444-8>
- [16] T. B. Sasongko, H. Haryoko, And A. Amrullah, "Analisis Efek Augmentasi Dataset Dan Fine Tune Pada Algoritma Pre-Trained Convolutional Neural Network (Cnn)," *Jurnal Teknologi Informasi Dan Ilmu Komputer (Jtiik)*, Vol. 10, No. 4, Pp. 763–768, Aug. 2023. [Online]. Available: <https://doi.org/10.25126/Jtiik.2023106583>
- [17] M. Fadhilatuzzahro, A. Fazrin, Z. I. Arishandy, T. A. Sukoco, And H. Maulana, "Optimalisasi Model Cnn Efficientnet-B0 Dengan Fine Tuning Untuk Klasifikasi Penyakit Buah Jeruk," *Jurnal Ilmiah Teknologi Informasi Dan Robotika*, Vol. 7, No. 1, Pp. 23–30, Dec. 2025. [Online]. Available: <https://doi.org/10.33005/Jifti.V7i1.162>