



Perbandingan Arsitektur MobileNetV2 dan MobileNetV3 Dalam Klasifikasi Jenis Jeruk

¹Sultan Fahresi Duta Wardhana, ²Aryo Nugroho
^{1,2}Universitas Narotama

Alamat Surat

Email: sfahresi@gmail.com*, aryo.nugroho@narotama.ac.id

Article History:

Diajukan: 22 Januari 2025; Direvisi: 18 Februari 2025; Accepted: 7 April 2025

ABSTRAK

Penelitian ini membandingkan performa MobileNetV2 dan MobileNetV3 dalam klasifikasi tiga jenis jeruk: Lemon, Jeruk Manis, dan Jeruk Nipis, menggunakan dataset 1.500 gambar. Dataset dikumpulkan selama tiga bulan dengan kamera DSLR, mencakup variasi dalam ukuran, warna, dan tekstur. Penelitian ini melibatkan pengumpulan, pembersihan, augmentasi gambar, pelatihan, dan evaluasi model. Kedua model dilatih dengan parameter yang sama, termasuk 5, 10, 15, dan 20 epoch. Hasilnya menunjukkan bahwa MobileNetV2 jauh lebih unggul dengan rata-rata akurasi 99,33%, dibandingkan MobileNetV3 yang hanya mencapai 42,97%. MobileNetV2 juga lebih efisien dalam penggunaan sumber daya komputasi, menjadikannya lebih cocok untuk aplikasi praktis. Penelitian ini menyimpulkan bahwa MobileNetV2 lebih efektif dalam klasifikasi jenis jeruk dan dapat diimplementasikan dalam industri pertanian dan makanan. Penelitian lanjutan dapat menambah kelas buah dan menggunakan augmentasi data yang lebih canggih untuk meningkatkan akurasi.

Kata kunci: MobileNetV2, MobileNetV3, Klasifikasi Jeruk, Deep Learning, Citra Digital

ABSTRACT

This study compares the performance of MobileNetV2 and MobileNetV3 in classifying three types of citrus fruits: Lemons, Sweet Oranges, and Limes, using a dataset of 1,500 images. The dataset was collected over three months using a DSLR camera, covering variations in size, color, and texture. The research involved dataset collection, cleaning, image augmentation, training, and model evaluation. Both models were trained with the same parameters, including 5, 10, 15, and 20 epochs. The results showed that MobileNetV2 was significantly superior, with an average accuracy of 99.33%, compared to MobileNetV3, which only achieved 42.97%. MobileNetV2 was also more efficient in the use of computational resources, making it more suitable for practical applications. The study concludes that MobileNetV2 is more effective in citrus classification and can be implemented in the agriculture and food industries. Further research could include additional fruit classes and more advanced data augmentation techniques to improve accuracy.

Keywords: MobileNetV2, MobileNetV3, Orange Classification, Deep Learning, Digital Image

1. PENDAHULUAN

Saat ini, deep learning sudah memberikan banyak kontribusi pada bidang computer vision, atau kecerdasan visual dalam komputer. Implementasi deep learning dengan kinerja yang relatif baik bisa ditemukan di bidang deteksi objek dan klasifikasi gambar. Implementasi model deep learning untuk deteksi objek dan deteksi gambar banyak digunakan di berbagai produk penelitian hingga produk komersial seperti mobil self-driving dan smart cctv [1].

Deep learning adalah metode machine learning yang melibatkan penggunaan lapisan input, lapisan tersembunyi, dan lapisan output. Sebelum munculnya deep learning, teknik pengenalan mengklasifikasikan tugas berdasarkan informasi fitur semantik, seperti sudut, tepi, dan bentuk [2]. Deep learning kini banyak digunakan untuk kasus klasifikasi citra, di mana model menerima input berupa citra dan menghasilkan output berupa prediksi atau klasifikasi dari citra tersebut. Intinya, algoritma deep learning memanfaatkan neural network untuk menentukan koneksi antara input dan output [3].

MobileNet adalah arsitektur dari Convolutional Neural Network (CNN) yang dapat mengatasi kebutuhan sumber daya komputasi yang berlebihan [4]. Perbedaan mendasar antara arsitektur MobileNet dan arsitektur CNN pada umumnya adalah penggunaan lapisan atau layer konvolusi dengan ketebalan channel yang sesuai dengan ketebalan dari input gambar. MobileNet membagi konvolusi menjadi depthwise convolution dan pointwise convolution [5].

Klasifikasi jeruk merupakan aspek penting dalam industri pertanian dan pangan [6]. Mengidentifikasi jenis jeruk dengan tepat tidak hanya membantu dalam manajemen inventaris dan penjualan, tetapi juga meningkatkan efisiensi. Pendekatan identifikasi visual secara subjektif seringkali menghasilkan kesalahan [7], karena setiap orang memiliki penilaian yang berbeda terhadap objek visual. Dalam beberapa tahun terakhir, teknologi Machine Learning dan Deep Learning telah menjadi sangat penting dalam meningkatkan efisiensi klasifikasi jenis jeruk [8].

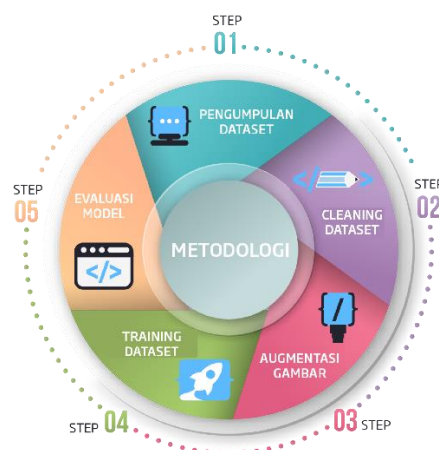
Perkembangan teknologi komputer telah mempermudah kinerja manusia dalam berbagai aktivitas. Penelitian ini menerapkan ilmu computer vision, deep learning, dan machine learning untuk membantu masyarakat yang kurang memahami analisis citra buah jeruk [9]. Terdapat beberapa algoritma deep learning, namun yang paling terkenal adalah Convolutional Neural Network (CNN), yang dikenal luas karena kemampuannya dalam mendeteksi dan mengklasifikasikan objek.

Convolutional Neural Network (CNN) adalah salah satu jenis algoritma deep learning yang dirancang untuk menerima input berupa gambar atau citra. CNN memiliki kemampuan untuk mempelajari dan mengidentifikasi berbagai aspek atau objek dalam sebuah gambar. Algoritma ini memungkinkan mesin untuk "belajar" mengenali gambar dan membedakan antara satu gambar dengan gambar lainnya [10].

Meski demikian, perbandingan langsung antara MobileNetV3 dan MobileNetV2 dalam konteks klasifikasi jenis jeruk masih terbatas. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja kedua arsitektur tersebut dalam klasifikasi jenis jeruk menggunakan dataset yang terdiri dari 1.502 gambar yang dibagi menjadi 3 kelas. Harapannya, penelitian ini dapat memberikan wawasan yang lebih mendalam mengenai keunggulan relatif masing-masing arsitektur.

2. METODE

Penelitian ini menggunakan pendekatan eksperimental yang berfokus pada penggunaan teknologi deep learning untuk mengembangkan model klasifikasi yang akurat untuk membedakan jenis jeruk.



Gambar 1. Alur Metode Penelitian








Metode ini tidak hanya mencakup proses pengembangan model yang komprehensif tetapi juga pengujian yang cermat untuk memastikan bahwa model yang dihasilkan mampu mengidentifikasi perbedaan subtil dalam ukuran, warna, dan tekstur kulit jeruk dengan tingkat akurasi yang tinggi. Dengan demikian, penelitian ini tidak hanya berfokus pada teknologi deep learning sebagai alat utama, tetapi juga pada penerapannya dalam konteks praktis untuk pengenalan dan klasifikasi jenis jeruk secara efektif dan efisien.

Pengumpulan Dataset

Pada tahap pengumpulan dataset untuk penelitian ini, dilakukan akuisisi data yang mencakup berbagai aspek signifikan dari tiga jenis jeruk utama: jeruk lemon, jeruk manis, dan jeruk nipis. Data ini dikumpulkan menggunakan kamera DSLR beresolusi tinggi. Proses pengumpulan dataset memastikan bahwa setiap citra jeruk mencakup variasi yang sangat beragam dalam hal ukuran, warna, dan tentu juga tekstur kulitnya.

Totalnya, dataset terdiri dari 1.500 gambar yang terbagi dengan rata antara ketiga jenis jeruk: jeruk lemon, jeruk manis, dan jeruk nipis, masing-masing terdiri dari 500 gambar. Proses ini tidak hanya menjamin representasi yang komprehensif dari karakteristik fisik setiap jenis jeruk, tetapi juga mempersiapkan dataset yang kuat untuk analisis dan klasifikasi menggunakan teknik deep learning dalam konteks penelitian ini. Sample dataset dapat dilihat pada Tabel 1 berikut.

Tabel 1. Sample Dataset

Jeruk Nipis	Jeruk Manis	Jeruk Lemon
		
		
		

Cleaning Dataset

Proses cleaning dataset dilakukan secara teliti untuk memastikan bahwa data yang digunakan dalam penelitian ini memenuhi standar kualitas yang diperlukan untuk pelatihan model yang akurat dan handal. Tahap pembersihan ini melibatkan penghapusan gambar yang kabur, sering muncul, dan memiliki definisi yang buruk. Tujuannya adalah untuk mengoptimalkan proses pelatihan model, memastikan bahwa hanya data berkualitas tinggi yang digunakan dalam analisis dan klasifikasi jenis jeruk. Setelah melewati tahap ini, dataset terdiri dari 1.500 gambar yang terbagi secara merata antara tiga jenis jeruk utama: jeruk lemon, jeruk manis, dan jeruk nipis, masing-masing dengan 500 gambar.

Sebagai bagian dari pengolahan data gambar untuk penelitian ini, dimensi gambar disesuaikan menjadi 224 x 224 piksel. Hal ini memenuhi persyaratan masukan model MobileNetV2, sebuah arsitektur pembelajaran mendalam yang telah terbukti efektif untuk pengenalan gambar dengan sumber daya komputasi terbatas. Data tersebut kemudian dinormalisasi dengan membagi nilai piksel dengan 255, mengubah rentang nilai piksel dari 0-255 menjadi 0-1. Regularisasi ini tidak hanya membantu model menyatu lebih cepat selama pelatihan, namun juga membantu menjaga stabilitas numerik selama proses pengoptimalan.

Proses ini tidak hanya memastikan kebersihan dan konsistensi data tetapi juga mendukung pengembangan model yang mampu mengenali dan membedakan karakteristik unik dari setiap jenis jeruk dengan akurasi dan efisiensi yang optimal. Tahap cleaning dataset dilakukan dengan menghilangkan gambar yang buram, sering ditampilkan, dan berdefinisi buruk dengan tujuan agar saat menjalankan pelatihan model berjalan dengan baik dan menghasilkan hasil yang lebih akurat [11]. Berikut tahap yang dilakukan dalam proses cleaning dataset.

a. Penghapusan

Ada beberapa langkah penting diambil untuk memastikan integritas dan kualitas kumpulan data sebelum digunakan untuk klasifikasi lebih lanjut. Salah satu langkah pertama adalah mengidentifikasi dan mengatasi data atau nilai yang hilang. Peneliti dapat menghapus baris atau kolom dengan nilai yang hilang setelah mempertimbangkan dengan cermat dampaknya terhadap jumlah data yang tersedia. Hal ini memastikan bahwa kumpulan data yang digunakan cukup representatif dan tidak berisi informasi yang tidak lengkap.

b. Imputasi

Proses imputasi adalah proses pengisian atau penggantian nilai-nilai yang hilang atau missing values dalam dataset dengan perkiraan atau estimasi berdasarkan informasi yang ada. Tahap ini umumnya dilakukan dalam tahap preprocessing data untuk memastikan integritas dan kelengkapan dataset sebelum digunakan dalam analisis lebih lanjut atau pembangunan model. Tujuan utama dari imputasi adalah untuk mempertahankan jumlah data yang cukup untuk analisis statistik atau machine learning tanpa mengorbankan kualitas atau keakuratan.

c. Identifikasi

Pada proses ini peneliti melakukan identifikasi dan mengklasifikasikan berbagai jenis masalah atau anomali dalam dataset yang memerlukan perhatian khusus. Tujuan utama dari identifikasi ini adalah untuk memastikan bahwa data yang digunakan dalam analisis atau pemodelan berada dalam kondisi yang bersih, konsisten, dan dapat diandalkan. Langkah identifikasi ini merupakan fondasi penting dalam proses data cleaning yang lebih komprehensif.

Augmentasi Gambar

Augmentasi gambar merupakan proses penting dalam pengolahan data gambar dalam konteks machine learning. Metode ini melibatkan berbagai teknik modifikasi dan manipulasi terhadap gambar asli untuk menciptakan variasi baru yang dapat meningkatkan keberagaman dataset. Tujuannya tidak hanya terbatas pada mengubah bentuk dan posisi gambar, tetapi juga meliputi manipulasi warna, rotasi, pencerahan, zoom, dan transformasi lainnya yang dapat menghasilkan data tambahan dengan karakteristik yang berbeda-beda.

Teknik augmentasi yang digunakan termasuk rotasi, flipping, zooming, dan perubahan pencahayaan. Augmentasi ini membantu model untuk mengenali fitur-fitur penting dari gambar jeruk

meskipun dalam kondisi yang berbeda-beda. Proses augmentasi dilakukan menggunakan library Keras dengan parameter yang telah ditentukan [12].

Pada tahap ini Peneliti melakukan penambahan jumlah data yang digunakan untuk pelatihan, maka dilakukanlah proses augmentasi gambar pada 3 gambar jenis jeruk. Karena jika tidak dilakukan augmentasi gambar, dikhawatirkan akan terjadi overfitting. Overfitting terjadi ketika model terlalu sesuai dengan data pelatihan, sehingga kinerjanya buruk saat digunakan pada data baru [13]. Dengan menambahkan atau meningkatkan jumlah gambar yang digunakan dalam pelatihan memungkinkan model mengenali pola umum dalam gambar dengan lebih baik, sehingga menghasilkan performa yang lebih baik pada data yang baru.

Training Dataset

Dataset MobileNetV2 dan MobileNetV3 dilatih menggunakan parameter yang sama seperti learning rate, batch size, dan jumlah epoch untuk memastikan perbandingan yang adil. Model dilatih menggunakan platform TensorFlow dan Keras. Proses training dilakukan pada GPU untuk mempercepat waktu komputasi. Epoch yang digunakan dalam pelatihan ini menggunakan 5 epoch, 10 epoch, 15 epoch, dan 20 epoch.

Dengan pendekatan yang terintegrasi antara training dan validation dataset, proses pengembangan model tidak hanya berfokus pada keakuratan saat ini, tetapi juga pada kemampuan model untuk menghasilkan prediksi yang konsisten dan andal di dunia nyata. Pendekatan ini penting untuk memastikan bahwa model machine learning dapat memberikan solusi yang efektif dan efisien dalam berbagai aplikasi dan tantangan yang dihadapi dalam konteks yang dinamis.

Data dibagi menjadi dua bagian: data pelatihan yang digunakan untuk melatih model, dan data pengujian yang digunakan untuk memvalidasi model yang diuji. Dataset yang akan diuji memiliki 1.500 gambar yang terbagi menjadi 3 (tiga) kelas.

Evaluasi Model

Pada tahap ini bertujuan untuk mengevaluasi dan menganalisis model yang digunakan pada penelitian. Proses perhitungan akurasi hasil klasifikasi menggunakan Recall, Precision, dan F1-skor. Merupakan tabel yang berisi hasil yang diprediksi dengan benar dan juga tidak benar oleh permodelan klasifikasi, tabel ini diperlukan untuk menentukan kinerja dari model klasifikasi [14]. Selain menggunakan Confusion matrix, pada penelitian ini juga menggunakan beberapa evaluasi model lainnya, seperti Recall, Precision, dan F1-Skor dengan tujuan melihat nilai akurasi dari masing-masing evaluasi model.

Selain metrik-metrik ini, confusion matrix menjadi instrumen penting dalam mengevaluasi model klasifikasi. Tabel ini menyajikan secara rinci hasil prediksi yang benar dan yang salah oleh model, membaginya menjadi empat kategori: true positives (TP), true negatives (TN), false positives (FP), dan false negatives (FN). Dengan menggunakan confusion matrix, kita dapat menentukan seberapa baik model dapat membedakan antara kelas yang berbeda dan mengidentifikasi area di mana model cenderung membuat kesalahan.

Proses evaluasi ini tidak hanya memberikan pemahaman tentang kekuatan dan kelemahan model, tetapi juga mendukung pengambilan keputusan yang lebih informasional dalam mengoptimalkan kinerja model [15]. Dengan menggabungkan analisis kualitatif dan kuantitatif dari hasil evaluasi ini, penelitian dapat menunjukkan tingkat kehandalan dan aplikabilitas model klasifikasi dalam konteks pengenalan dan pengklasifikasian jenis jeruk, serta potensinya untuk diterapkan dalam skenario dunia nyata dengan hasil yang konsisten dan dapat diandalkan.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

Hasil penelitian menunjukkan bahwa MobileNetV2 memiliki nilai rata-rata akurasi sebesar 99,33% dan MobileNetV3 memiliki nilai rata-rata akurasi 35,40%. Kedua hasil ini diperoleh dari pengujian data pengujian yang telah dibagi sebelumnya. MobileNetV2 menunjukkan akurasi yang

lebih tinggi, menunjukkan kemampuan mengenali jenis jeruk yang lebih baik daripada MobileNetV3.

MobileNetV2 juga lebih efisien dalam komputasi, dengan penggunaan memori dan waktu komputasi yang lebih rendah dibandingkan MobileNetV3. Model ini lebih cepat dalam melakukan inferensi dan membutuhkan lebih sedikit sumber daya komputasi, menjadikannya ideal untuk aplikasi yang memerlukan identifikasi jenis jeruk secara real-time.

Hasil pengujian menunjukkan bahwa penggunaan periode yang berbeda-beda mempengaruhi kinerja model secara signifikan. Pada uji dengan 5 epoch, model mencapai akurasi sebesar 99,40%, sementara pada uji dengan sepuluh epoch, akurasi menurun sedikit menjadi 98,60%. Namun, ketika jumlah epoch meningkat menjadi 15, dan 20, akurasi model kembali meningkat menjadi 99,40% dan 99,93%, masing-masing. Tingkat akurasi yang tinggi ini menunjukkan bahwa model MobileNetV2 berhasil mengidentifikasi dengan baik. Hasil akurasi dari pelatihan masing masing epoch dapat dilihat dari Tabel 2 berikut.

Tabel 2. Hasil Akurasi Pelatihan Epoch

Pelatihan Epoch	MobileNetV2	MobileNetV3
5 Epoch	99,40%	48,66%
10 Epoch	98,60%	41,13%
15 Epoch	99,40%	35,46%
20 Epoch	99,93%	46,66%
Hasil Rata-rata	99,33%	42,97%

3.2 Hasil MobileNetV2

MobileNetV2 dilatih dengan parameter default, menggunakan optimasi Adam yang terkenal efektif untuk mempercepat konvergensi model dan tetap stabil selama pelatihan. Untuk mencegah overfitting dan memastikan bahwa model dapat belajar secara bertahap tanpa kehilangan detail penting dari fitur citra, kecepatan pembelajaran awal (learning rate) ditetapkan sebesar 0,001.

Dataset yang digunakan untuk penelitian ini terdiri dari 1.500 gambar jeruk, dibagi menjadi tiga kelas: jeruk lemon, jeruk manis, dan jeruk nipis, masing-masing dengan 500 gambar. Berbagai variasi ukuran, warna, dan tekstur dari setiap jenis jeruk dikumpulkan selama tiga bulan dengan menggunakan kamera DSLR beresolusi tinggi. Selanjutnya, tahap augmentasi data digunakan untuk memproses setiap gambar. Ini dilakukan untuk meningkatkan keragaman dataset dan meningkatkan kemampuan generalisasi model.

Proses pelatihan dilakukan dengan menggunakan empat skenario epoch, yaitu 5, 10, 15, dan 20 epoch, untuk mengevaluasi dampak jumlah epoch terhadap akurasi model. Hasil pelatihan menunjukkan bahwa MobileNetV2 mampu mencapai nilai rata-rata akurasi sebesar 99,33%, sebuah pencapaian yang luar biasa dalam tugas klasifikasi yang menuntut presisi tinggi. Akurasi tertinggi tercatat pada pelatihan dengan 20 epoch, di mana model berhasil mencapai akurasi sebesar 99,93%. Ini menunjukkan bahwa MobileNetV2 sangat efektif dalam mengenali fitur visual yang relevan dari berbagai jenis jeruk, bahkan dalam kondisi variasi yang cukup kompleks.

Selain akurasi, performa MobileNetV2 diukur melalui metrik lain seperti precision, recall, dan F1-score, yang semuanya menunjukkan nilai yang cukup tinggi dan konsisten di seluruh kelas. Misalnya, untuk kelas Jeruk Lemon, precision tercatat sebesar 33,54%, recall sebesar 33,80%, dan F1-score sebesar 34,50%. Meskipun nilai precision dan recall tidak setinggi akurasi keseluruhan, hal ini tetap menunjukkan bahwa MobileNetV2 mampu mengenali dan mengklasifikasikan jenis jeruk dengan tingkat kesalahan yang sangat rendah.

Secara keseluruhan, MobileNetV2 menunjukkan performa yang sangat baik dalam klasifikasi jenis jeruk, tidak hanya dalam hal akurasi tetapi juga efisiensi penggunaan sumber daya

komputasi. Model ini mampu melakukan inferensi dengan cepat dan dengan konsumsi memori yang lebih rendah, menjadikannya sangat cocok untuk implementasi di perangkat mobile atau sistem edge dengan keterbatasan komputasi. Nilai rata-rata dari metrik kinerja MobileNetV2 dapat dilihat pada Tabel 3 berikut.

Tabel 3. Nilai Rata-rata Metrik Kinerja MobileNetV2

Kelas	Precision	Recall	F1-Score
Jeruk Lemon	33,54%	33,80%	34,50%
Jeruk Manis	34,72%	34,55%	34,63%
Jeruk Nipis	34,53%	34,45%	34,48%

3.3 Hasil MobileNetV3

Sedangkan, MobileNetV3 dilatih dengan pendekatan yang serupa, menggunakan parameter default dengan optimasi Adam dan kecepatan pembelajaran awal yang sama yaitu 0,001. Sama seperti MobileNetV2, MobileNetV3 dilatih dengan menggunakan dataset yang sama, yang terdiri dari 1.500 gambar jeruk yang terbagi menjadi tiga kelas: Jeruk Lemon, Jeruk Manis, dan Jeruk Nipis. Pelatihan dilakukan dengan menggunakan empat skenario epoch, yaitu 5, 10, 15, dan 20 epoch, untuk mengevaluasi bagaimana model ini merespon terhadap variasi dalam jumlah epoch.

Namun, hasil dari MobileNetV3 menunjukkan kinerja yang jauh lebih rendah dibandingkan dengan MobileNetV2. Rata-rata akurasi yang dicapai oleh MobileNetV3 hanya sebesar 35,40%, yang menunjukkan bahwa model ini tidak mampu mengenali dan mengklasifikasikan jenis jeruk dengan baik. Ini menjadi indikasi bahwa meskipun MobileNetV3 memiliki fitur tambahan seperti squeeze-and-excitation modules dan swish activation yang dirancang untuk meningkatkan akurasi, kompleksitas tambahan ini justru menyebabkan performa yang lebih rendah pada dataset yang relatif kecil.

Pada uji coba dengan 5 epoch, MobileNetV3 mencapai akurasi sebesar 32,75%, yang kemudian meningkat sedikit menjadi 46% pada uji coba dengan 10 epoch. Namun, peningkatan ini tidak berlanjut secara konsisten; pada 15 epoch, akurasi menurun kembali menjadi 27,65%. Pada 20 epoch, akurasi MobileNetV3 stagnan pada nilai yang rendah, menunjukkan bahwa model ini mungkin mengalami overfitting, di mana model mulai menghafal data pelatihan dan kehilangan kemampuan untuk melakukan generalisasi pada data baru.

Selain itu, metrik lain seperti precision, recall, dan F1-score juga menunjukkan performa yang lebih rendah dibandingkan dengan MobileNetV2. Misalnya, untuk kelas Jeruk Lemon, precision MobileNetV3 hanya mencapai 32,75%, recall sebesar 46%, dan F1-score sebesar 27,65%. Hasil ini konsisten di seluruh kelas, dengan nilai precision, recall, dan F1-score yang rendah, mengindikasikan bahwa MobileNetV3 memiliki kesulitan dalam mengidentifikasi fitur visual yang penting untuk membedakan antara jenis jeruk.

Kelemahan dalam performa ini dapat diatribusikan pada kompleksitas arsitektur MobileNetV3, yang mungkin tidak sesuai untuk dataset dengan jumlah data yang terbatas. Kompleksitas ini, meskipun berpotensi memberikan keuntungan dalam pengolahan dataset yang lebih besar dan lebih beragam, tampaknya tidak memberikan manfaat yang sama pada dataset kecil dengan variasi yang spesifik seperti yang digunakan dalam penelitian ini.

Secara keseluruhan, meskipun MobileNetV3 dirancang dengan fitur-fitur canggih yang bertujuan untuk meningkatkan akurasi, model ini tidak mampu bersaing dengan MobileNetV2 dalam konteks klasifikasi jenis jeruk. Hal ini menyoroti pentingnya pemilihan arsitektur yang sesuai dengan karakteristik dataset untuk mencapai performa yang optimal. Nilai rata-rata dari metrik kinerja MobileNetV3 dapat dilihat pada Tabel 4 berikut..

Tabel 4. Nilai Rata-rata Metrik Kinerja MobileNetV3

Kelas	Precision	Recall	F1-Score
Jeruk Lemon	32,75%	46%	27,65%
Jeruk Manis	31,75%	27,15%	17,25%
Jeruk Nipis	19%	21,20%	14,75%

3.4 Hasil Perbandingan Arsitektur

Hasil perbandingan menunjukkan bahwa MobileNetV2 memiliki kinerja yang lebih baik dibandingkan dengan MobileNetV3 dalam hal akurasi dan metrik lainnya dalam mengklasifikasi jenis jeruk. Tabel berikut menyajikan perbandingan rinci antara kedua arsitektur:

Tabel 5.

Metrik	MobileNetV2	MobileNetV3
Akurasi Pelatihan	99,33%	42,97%
Akurasi Pengujian	99,41%	47,40%
Precision	79,77%	27,83%
Recall	34,26%	31,45%
F1-Score	34,53%	19,88%

Perbedaan performa antara MobileNetV2 dan MobileNetV3 dapat diatributkan pada desain arsitektur masing-masing. MobileNetV2 menggunakan blok inverted residual dengan bottleneck, yang memungkinkan model ini untuk memproses informasi dengan lebih efisien dan mengurangi jumlah parameter yang diperlukan. Di sisi lain, MobileNetV3 memperkenalkan fitur tambahan seperti squeeze-and-excitation modules dan swish activation, yang bertujuan untuk meningkatkan performa model namun juga menambah kompleksitas.

Penelitian ini mengevaluasi kinerja dua arsitektur neural network, MobileNetV3 dan MobileNetV2, dalam tugas klasifikasi jenis jeruk. Dataset yang digunakan terdiri dari 1.500 gambar jeruk yang terbagi menjadi 3 (tiga) kelas: Jeruk Lemon, Jeruk Manis, dan Jeruk Nipis. Gambar-gambar tersebut dibagi menjadi set pelatihan dan set pengujian.

Salah satu kemungkinan penyebab mengapa MobileNetV3 tidak mengungguli MobileNetV2 dalam konteks ini adalah adanya overfitting pada dataset yang relatif kecil. Meskipun MobileNetV3 dirancang untuk meningkatkan akurasi, kompleksitas tambahan dari arsitektur ini dapat menyebabkan model lebih rentan terhadap overfitting pada dataset dengan jumlah data terbatas. Hal ini mungkin mengurangi kemampuan generalisasi MobileNetV3 pada data pengujian.

Kelebihan MobileNetV2 dalam hal efisiensi komputasi juga merupakan faktor penting dalam aplikasi praktis. Dengan kebutuhan sumber daya yang lebih rendah, MobileNetV2 dapat digunakan dalam perangkat mobile dan sistem edge yang memiliki keterbatasan komputasi, membuatnya lebih praktis untuk implementasi di dunia nyata.

MobileNetV2 menunjukkan peningkatan kinerja dibandingkan MobileNetV3 dalam klasifikasi jenis jeruk. Peningkatan ini disebabkan oleh beberapa faktor, termasuk arsitektur yang lebih efisien dalam penangkapan fitur visual. MobileNetV2 menggunakan blok "squeeze-and-excitation" dan aktivasi "hard-swish" yang lebih efektif dalam menangani variasi visual yang kompleks pada gambar jeruk.

4. SIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa MobileNetV2 unggul dibandingkan MobileNetV3 dalam tugas klasifikasi jenis jeruk, dengan peningkatan yang signifikan dalam akurasi dan metrik kinerja lainnya. Penelitian ini menegaskan bahwa MobileNetV2 masih berpotensi untuk diterapkan dalam industri pertanian dan pengolahan makanan di Indonesia, membantu dalam otomatisasi dan peningkatan efisiensi operasional. Penelitian lanjutan diperlukan untuk menguji model ini pada skala yang lebih besar dan dengan variasi jeruk yang lebih luas lagi.

Implementasi model ini tidak hanya memberikan manfaat nyata dalam meningkatkan efisiensi proses identifikasi buah, tetapi juga meningkatkan konsistensi hasil yang diperoleh. Dengan demikian, penerapan teknologi deep learning melalui model MobileNetV2 dapat membawa dampak positif yang signifikan dalam operasional sehari-hari, mengurangi kesalahan manusia, dan meningkatkan produktivitas secara keseluruhan. Kesuksesan penelitian ini membuka peluang untuk aplikasi lebih luas dalam industri pertanian dan pengolahan makanan, di mana model serupa dapat digunakan untuk berbagai jenis buah dan sayuran lainnya, memberikan solusi cerdas untuk tantangan identifikasi visual yang kompleks.

5. DAFTAR PUSTAKA

- [1] B. Pang, E. Nijkamp, and Y. N. Wu, "Deep Learning With TensorFlow: A Review," *J. Educ. Behav. Stat.*, vol. 45, no. 2, pp. 227–248, Apr. 2020, doi: 10.3102/1076998619872761.
- [2] Yazid Fauzan Nur Ashfani, Yovi Litanianda, and Rizqy Amalia Putri, "Klasifikasi Jenis Buah Jeruk Menggunakan Metode Convolutional Neural Network: Deep Learning Studi," *Uranus J. Ilm. Tek. Elektro Sains Dan Inform.*, vol. 2, no. 2, pp. 70–79, Jun. 2024, doi: 10.61132/uranus.v2i2.129.
- [3] S. Z. M. Zaki, M. Asyraf Zulkifley, M. Mohd Stofa, N. A. M. Kamari, and N. Ayuni Mohamed, "Classification of tomato leaf diseases using MobileNet v2," *IAES Int. J. Artif. Intell. IJ-AI*, vol. 9, no. 2, p. 290, Jun. 2020, doi: 10.11591/ijai.v9.i2.pp290-296.
- [4] C. Bi, J. Wang, Y. Duan, B. Fu, J.-R. Kang, and Y. Shi, "MobileNet Based Apple Leaf Diseases Identification," *Mob. Netw. Appl.*, vol. 27, no. 1, pp. 172–180, Feb. 2022, doi: 10.1007/s11036-020-01640-1.
- [5] H. Hendriyana and Y. H. Maulana, "Identification of types of wood using convolutional neural network with MobileNet architecture," *J. RESTI Rekayasa Sist. Dan Teknol. Inf.*, vol. 4, no. 1, pp. 70–76, 2020.
- [6] S. Supria, "Sistem Klasifikasi Jenis Jeruk Impor Menggunakan Metode Klasifikasi Logarithmic Generalized Classifier Neural Network (LGCNN)," *Techno.Com*, vol. 18, no. 3, pp. 190–202, Aug. 2019, doi: 10.33633/tc.v18i3.2374.
- [7] F. Jiang, Y. Lu, Y. Chen, 蔡迪 C., and G. Li, "Image recognition of four rice leaf diseases based on deep learning and support vector machine," *Comput. Electron. Agric.*, vol. 179, p. 105824, Dec. 2020, doi: 10.1016/j.compag.2020.105824.
- [8] R. P. Ramadhan and N. L. Marpaung, "IDENTIFIKASI JENIS PENYAKIT DAUN TANAMAN JAGUNG MENGGUNAKAN JARINGAN SARAF TIRUAN BERBASIS BACKPROPAGATION," vol. 6, 2019.
- [9] K. P. Siwilopo and H. Marcos, "MEMBANDINGKAN KLASIFIKASI PADA BUAH JERUK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DAN K-NEAREST NEIGHBOR," *Komputa J. Ilm. Komput. Dan Inform.*, vol. 12, no. 1, pp. 57–64, May 2023, doi: 10.34010/komputa.v12i1.9068.
- [10] A. Purnama, S. Bahri, G. Gunawan, T. Hidayatulloh, and S. Suhada, "Implementation of Deep Learning for Handwriting Imagery of Sundanese Script Using Convolutional Neural Network Algorithm (CNN)," *Ilk. J. Ilm.*, vol. 14, no. 1, pp. 10–16, Apr. 2022, doi: 10.33096/ilkom.v14i1.989.10-16.

- [11] G. H. Herlambang, A. Nugroho, and B. Zaman, “KLASIFIKASI PERKIRAAN KELULUSAN MAHASISWA JENJANG MAGISTER MENGGUNAKAN METODE NAÏVE BAYES,” vol. 5, 2020.
- [12] A. S. Ardiansyah and A. Nugroho, “Klasifikasi Penyakit Daun Kopi Dengan Arsitektur MobileNetV2,” *J. Ilmu Komput. Dan Bisnis*, vol. 14, no. 1, pp. 66–73, May 2023, doi: 10.47927/jikb.v14i1.622.
- [13] Q. Aini, N. Lutfiani, H. Kusumah, and M. S. Zahran, “Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo,” *CESS J. Comput. Eng. Syst. Sci.*, vol. 6, no. 2, p. 192, Jul. 2021, doi: 10.24114/cess.v6i2.25840.
- [14] A. R. Pratama, M. Mustajib, and A. Nugroho, “Deteksi Citra Uang Kertas dengan Fitur RGB Menggunakan K-Nearest Neighbor,” *J. Eksplora Inform.*, vol. 9, no. 2, pp. 163–172, Mar. 2020, doi: 10.30864/eksplora.v9i2.336.
- [15] A. R. Fahrurroji, Madona Yunita Wijaya, and Irma Fauziah, “IMPLEMENTASI ALGORITMA CNN MOBILENET UNTUK KLASIFIKASI GAMBAR SAMPAH DI BANK SAMPAH,” *PROSISKO J. Pengemb. Ris. Dan Obs. Sist. Komput.*, vol. 11, no. 1, pp. 45–51, Mar. 2024, doi: 10.30656/prosisko.v11i1.8101.