

# Pendeteksi Gambar Jeruk Berdasarkan Kualitas Visual Menggunakan Arsitektur VGG-16 Pada Kategori Segar dan Busuk

<sup>1</sup>Inna Fatahna, <sup>2</sup>Danar Putra Pamungkas, <sup>3</sup>Danang Wahyu Widodo

<sup>1,2,3</sup> Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: <sup>1</sup>[innafatahna5@gmail.com](mailto:innafatahna5@gmail.com), <sup>2</sup>[danar@unpkediri.ac.id](mailto:danar@unpkediri.ac.id), <sup>3</sup>[danangwahyuwidodo@unpkediri.ac.id](mailto:danangwahyuwidodo@unpkediri.ac.id)

*Penulis Korespondens : Inna Fatahna*

**Abstrak**—Kualitas jeruk sangat memengaruhi nilai jual dan kepuasan konsumen, namun metode pemeriksaan manual sering kali lambat dan subjektif. Penelitian ini merancang sistem klasifikasi mutu jeruk menjadi tiga kelas, yaitu segar, mentah, dan busuk, menggunakan arsitektur VGG-16 yang dimodifikasi dengan pendekatan *transfer learning* dan teknik augmentasi data. Dataset berisi 1.280 citra jeruk yang telah melalui tahap pra-pemrosesan seperti perubahan ukuran, normalisasi, dan augmentasi visual. Model dilatih menggunakan algoritma Adam dan dievaluasi dengan metrik akurasi, presisi, *recall*, serta *F1-score*. Hasil menunjukkan akurasi hingga 97% tanpa *overfitting*. Sistem juga diimplementasikan dalam bentuk aplikasi berbasis web untuk mendukung inspeksi mutu secara *real-time*. Penelitian ini menunjukkan efektivitas penggunaan *deep learning* kualitas hortikultura secara cepat dan objektif.

**Kata Kunci**—Augmentasi Data, Jeruk Lokal, Klasifikasi Citra, *Transfer Learning*, VGG-16

**Abstract**—The quality of oranges significantly impacts their market value and consumer satisfaction, but manual inspection is often time-consuming and subjective. This study proposes a classification system that categorizes oranges into fresh or rotten using a modified VGG-16 architecture combined with transfer learning and image augmentation techniques. A dataset of 1,280 images was preprocessed through resizing, normalization, and visual augmentation. The model was trained using the Adam optimizer and evaluated with accuracy, precision, recall, and F1-score. Results showed a classification accuracy of up to 97% without overfitting. The system was also deployed as a web-based application, enabling real-time fruit quality assessment. This research highlights the effectiveness of deep learning in supporting fast, efficient, and objective inspection of horticultural products.

**Keywords**—Image classification, citrus quality, data augmentation, transfer learning, VGG-16

This is an open access article under the CC BY-SA License.



## I. PENDAHULUAN

Kualitas buah jeruk merupakan aspek krusial yang mempengaruhi nilai jual serta tingkat kepuasan konsumen. Penilaian mutu jeruk secara manual yang dilakukan oleh petani maupun pelaku industri sering kali memerlukan waktu yang lama dan rawan terhadap penilaian subjektif serta kesalahan manusia [1],[2]. Oleh karena itu, pengembangan sistem klasifikasi otomatis berbasis teknologi kecerdasan buatan menjadi solusi yang potensial untuk meningkatkan efisiensi serta akurasi dalam proses inspeksi mutu jeruk [3]. Dalam beberapa tahun terakhir, kemajuan metode pembelajaran mesin, khususnya *Convolutional Neural Networks* (CNN), telah

menunjukkan kinerja yang sangat baik dalam pengenalan citra digital dan klasifikasi objek, termasuk di bidang pertanian dan pangan [4],[5].

Berbagai penelitian terdahulu telah memanfaatkan CNN untuk mendeteksi serta mengklasifikasikan mutu buah secara otomatis. Sebagai contoh, Yanto et al. [2] menerapkan model CNN untuk klasifikasi kualitas apel dengan tingkat akurasi mencapai 82%. Penelitian oleh Anita et al. [6] mengembangkan sistem deteksi mutu mangga menggunakan *transfer learning* pada arsitektur ResNet dengan hasil yang menjanjikan. Namun demikian, sebagian besar studi tersebut masih menghadapi tantangan berupa variasi pencahayaan, latar belakang yang kompleks, serta kebutuhan akan dataset yang besar agar pelatihan model dapat berlangsung optimal. Studi yang dilakukan oleh Soekarta et al. [4] dan Rika et al. [7] menekankan pentingnya teknik augmentasi data serta *fine-tuning* model *pretrained* untuk mengatasi dataset *training* sekaligus meningkatkan kemampuan generalisasi model.


Berbeda dengan penelitian-penelitian sebelumnya, penelitian berfokus pada penggunaan arsitektur VGG-16, sebuah model CNN yang dikenal memiliki kedalaman serta kemampuan ekstraksi fitur yang kuat, untuk melakukan klasifikasi mutu jeruk ke dalam tiga kategori, yaitu segar, mentah, dan busuk. Pemanfaatan model VGG-16 yang telah *pretrained* pada dataset *ImageNet* serta modifikasi pada lapisan akhir arsitektur diharapkan mampu memberikan hasil klasifikasi yang lebih akurat dan andal dibandingkan metode konvensional maupun model CNN sederhana [8],[9]. Selain itu, penerapan teknik augmentasi citra dan evaluasi performa menggunakan metrik komprehensif seperti akurasi, presisi, *recall*, dan *F1-score* dilakukan guna memastikan validitas dan efektivitas sistem yang dikembangkan [10].

Tujuan utama penelitian ini adalah merancang dan mengimplementasikan sistem klasifikasi mutu jeruk berbasis *deep learning* dengan menggunakan model VGG-16 yang telah dimodifikasi. Secara khusus, penelitian ini bertujuan untuk mengumpulkan dan mempersiapkan dataset citra jeruk dengan distribusi kelas yang seimbang, menerapkan teknik *preprocessing* dan augmentasi untuk meningkatkan kualitas data pelatihan, mengkonfigurasi serta melatih model VGG-16 dalam klasifikasi mutu jeruk, dan melakukan evaluasi performa model menggunakan berbagai metrik untuk memastikan akurasi dan keandalan. Hipotesis utama yang diajukan menyatakan bahwa penerapan model VGG-16 dengan *transfer learning* serta augmentasi data dapat meningkatkan performa klasifikasi mutu jeruk jika dibandingkan dengan model CNN sederhana tanpa modifikasi.

Penelitian ini memberikan kontribusi signifikan di bidang teknik industri dan teknologi pangan, khususnya dalam pemanfaatan kecerdasan buatan untuk mendukung proses inspeksi mutu produk agrikultur secara otomatis, cepat, dan akurat. Selain itu, pengembangan aplikasi berbasis web sebagai media *deployment* juga memperluas jangkauan akses teknologi ini bagi petani dan pelaku industri. Dengan demikian, penelitian ini tidak hanya berkontribusi pada inovasi teknologi, tetapi juga mendukung pengembangan sistem pengendalian kualitas yang lebih efisien di sektor pangan. Lebih lanjut, aplikasi berbasis web ini memperluas cakupan dan aksesibilitas terhadap sistem pengendalian mutu yang lebih cerdas dan berkelanjutan di bidang agrikultur. Keberadaan sistem berbasis web yang dikembangkan juga membuka peluang integrasi dengan sistem distribusi hasil pertanian, sehingga dapat meningkatkan transparansi.

## II. METODE

Studi ini mengadopsi pendekatan eksperimental yang berfokus pada pemodelan citra digital dengan pemanfaatan teknologi kecerdasan buatan, khususnya jaringan saraf konvolusional *Convolutional Neural Network* (CNN). Tahapan dilakukan secara sistematis mulai dari pengumpulan data, pra-pemrosesan citra, pembangunan model dengan arsitektur VGG-16, pelatihan, hingga evaluasi model untuk klasifikasi mutu jeruk. Penelitian ini telah menggunakan pendekatan model pengembangan sistem terstruktur berurutan yang mengadaptasi prinsip dari siklus hidup pengembangan perangkat lunak SDLC (*System Development Life Cycle*). Pendekatan ini dipilih karena menyediakan alur kerja sistematis dari tahap awal hingga akhir proyek secara linier. Model ini terdiri atas beberapa fase yang dilakukan secara berurutan: subjek penelitian, *preprocessing*, implementasi, model VGG-16, dan evaluasi model [11],[12].



Gambar 1. Diagram Alur Metodologi Penelitian Klasifikasi Jeruk

### A. Subjek Penelitian dan Eksplorasi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari citra buah jeruk (*Citrus sp.*) yang diklasifikasikan ke dalam dua kategori utama, yaitu jeruk dalam kondisi segar dan jeruk yang telah mengalami pembusukan. Dataset berjumlah total 1.280 gambar, dengan distribusi seimbang antara kelas jeruk segar dan busuk untuk menjaga keseimbangan data yang sangat penting bagi pelatihan model yang efektif. Data dikumpulkan dari dokumentasi citra jeruk lokal dengan bervariasi kondisi dalam pencahayaan, tempat, latar belakang, objek buah sehingga dapat merefleksikan kondisi nyata berdasarkan hasil dataset yang diperoleh. Untuk memastikan validitas pelatihan dan evaluasi, dataset kemudian dibagi menjadi tiga subset berdasarkan proporsi 70% untuk data pelatihan, 20% untuk data validasi, dan 10% untuk data pengujian. Pembagian ini dilakukan secara stratifikasi, yang bertujuan mempertahankan distribusi proporsi kelas agar tetap seimbang pada setiap subset data yang digunakan [13],[6].

### B. Teknik Preprocessing Data

Sebelum dimasukkan ke dalam proses pelatihan, seluruh citra mengalami tahapan preprocessing untuk meningkatkan konsistensi serta kualitas data input. Proses preprocessing meliputi pengubahan ukuran (*resize*) gambar menjadi  $224 \times 224$  piksel, yang merupakan ukuran standar input yang dibutuhkan oleh arsitektur VGG-16. Selain itu, nilai piksel pada gambar dinormalisasi ke rentang antara 0 hingga 1 agar model dapat menerima *input* dengan skala yang seragam dan mengoptimalkan proses pembelajaran. Selain *resize* dan normalisasi, dilakukan juga teknik augmentasi data yang meliputi rotasi acak, *flipping* horizontal, *zooming*, dan *shifting* untuk memperkaya variasi gambar yang akan dilatih. Teknik augmentasi ini sangat penting untuk meningkatkan kemampuan generalisasi model, sehingga model dapat mengenali pola pada gambar dengan kondisi visual yang lebih beragam dan menghindari *overfitting*. Setiap citra dilabeli dalam format biner, di mana nilai 0 menunjukkan kelas jeruk busuk dan nilai 1 menunjukkan kelas jeruk segar, [14],[7].

### C. Implementasi dan Konfigurasi Arsitektur VGG-16

Dalam penelitian ini, digunakan arsitektur *Convolutional Neural Network* (CNN) VGG-16 yang telah melalui proses pelatihan awal menggunakan dataset *ImageNet*. Arsitektur tersebut

dipilih karena kemampuannya dalam mengekstraksi fitur visual secara mendalam berkat struktur jaringannya yang kompleks. Untuk menyesuaikan model dengan kebutuhan identifikasi antar kelas, arsitektur VGG-16 telah disesuaikan pada bagian atas (*top layer*) struktur jaringannya. Adaptasi ini meliputi penambahan lapisan flatten guna mengubah *output* fitur menjadi bentuk vektor satu dimensi, diikuti dengan penambahan lapisan dense berisi 256 unit neuron yang menggunakan fungsi aktivasi ReLU untuk memperkuat *non-linearitas* model. Dalam hal ini, langkah pencegahan terhadap overfitting akan ditambahkan lapisan dropout berkisar rasio 0.5. Pada bagian output, digunakan lapisan dengan satu neuron dan fungsi aktivasi sigmoid, yang cocok untuk skenario klasifikasi biner antara jeruk segar, mentah dan jeruk busuk. Selanjutnya, pelatihan model dijalankan menggunakan ukuran batch sebesar 32 dan dirancang untuk berlangsung selama 30 *epoch*, dengan tujuan agar model mempelajari representasi fitur optimal [15],[3].

#### D. Prosedur Pelatihan Model VGG-16

Pelatihan model penelitian ini dapat dilakukan dengan pendekatan *transfer learning*, yakni proses memanfaatkan bobot awal dari arsitektur VGG-16 yang telah dilatih menggunakan dataset *ImageNet* yang berskala cukup besar. Pada tahap awal, lapisan-lapisan awal dari model dibekukan (*freeze*) agar fitur umum yang telah dipelajari tidak mengalami perubahan selama proses *fine-tuning*. Selanjutnya, pelatihan dilakukan secara bertahap dengan menggunakan data latih yang telah melewati proses *preprocessing* dan augmentasi, sehingga model dapat belajar dari variasi visual yang lebih luas. Untuk meningkatkan efisiensi serta menghindari pelatihan yang tidak produktif, digunakan teknik *early stopping*, yaitu mekanisme penghentian pelatihan secara otomatis apabila tidak terdapat peningkatan performa dalam sejumlah *epoch* berturut-turut. Model terbaik yang menunjukkan hasil optimal validasi digunakan untuk evaluasi akhir pada data uji [16],[5].

#### E. Teknik Analisis Data dan Evaluasi Model

Setelah pelatihan selesai, dilakukan analisis performa model menggunakan data uji yang belum pernah dilihat selama pelatihan. Adanya evaluasi matriks utama dilakukan untuk hasil terbaik, seperti akurasi, presisi, *recall*, atau *F1-score* dalam memberikan *insight* baru pada gambaran menyeluruh berdasarkan kemampuan model ketika dapat mengklasifikasikan jeruk secara jenius. Akurasi mengukur proporsi prediksi yang benar dari keseluruhan data, presisi mengukur ketepatan prediksi positif, *recall* menilai kemampuan model dalam menangkap semua instance positif, dan *F1-score* memberikan keseimbangan antara presisi dan *recall*. Selain itu, digunakan juga confusion matrix untuk mengidentifikasi jenis dan jumlah kesalahan prediksi yang terjadi antara kelas jeruk segar, mentah, dan busuk. Hasil evaluasi kemudian divisualisasikan menggunakan grafik akurasi dan loss selama proses pelatihan per *epoch* serta *confusion matrix* yang menunjukkan distribusi prediksi benar dan salah [17],[2].

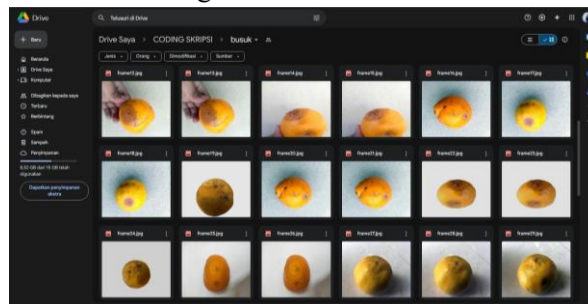
### III. HASIL DAN PEMBAHASAN

Bab ini memaparkan temuan dari proses pengembangan serta pengujian sistem klasifikasi kualitas jeruk menggunakan model VGG-16. Setiap bagian memaparkan hasil dari tahapan-tahapan utama penelitian, dimulai dari eksplorasi dataset, proses *preprocessing* citra, implementasi model, pelatihan, hingga evaluasi akhir. Fokus pembahasan tertuju pada kinerja model, kendala teknis yang ditemui selama pelatihan, serta langkah-langkah yang diambil untuk

memaksimalkan akurasi klasifikasi. Hasil disajikan dalam bentuk ringkasan numerik dan visual guna memberikan gambaran komprehensif terkait performa sistem klasifikasi ini.


#### A. Eksplorasi Dataset

Dataset yang digunakan dalam penelitian ini berjumlah 1.280 citra jeruk, dengan distribusi yang seimbang antara kelas jeruk segar, mentah, dan busuk (masing-masing sekitar 400-500 gambar). Gambar-gambar tersebut diperoleh dari sumber terbuka yang menampilkan beragam kondisi pencahayaan serta latar belakang yang merefleksikan situasi nyata di lapangan. Dalam tahap pelatihan model, dataset dibagi menjadi 896 sampel untuk pelatihan, 256 sampel untuk validasi, dan 128 sampel untuk pengujian. Pembagian ini dilakukan secara stratifikasi agar proporsi kelas tetap terjaga secara proporsional. Contoh citra dari tiap kelas disajikan pada Gambar 2, 3, dan 4 untuk memberikan gambaran visual karakteristik data.



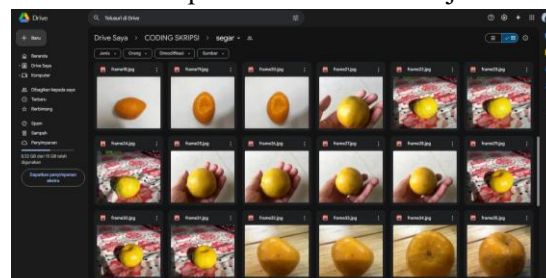
Gambar 2. Citra Jeruk Berkualitas Busuk

Pada Gambar 2 memperlihatkan jeruk dengan permukaan yang kusam, terdapat bintik hitam, serta sebagian kulit mulai mengalami pembusukan. Ciri-ciri ini umum ditemukan pada jeruk dengan kualitas rendah atau busuk sesuai dengan gambar yang ditampilkan.



Gambar 3. Citra Jeruk Berkualitas Mentah

Pada Gambar 3 menampilkan jeruk yang belum matang sempurna (jika kategori mentah terdapat dalam dataset), dengan kulit dominan berwarna hijau dan tekstur yang masih keras. Kategori ini diperlihatkan untuk menampilkan variasi kondisi jeruk.




Gambar 4. Citra Jeruk Berkualitas Segar

Pada Gambar 4 menggambarkan jeruk dengan warna kulit yang cerah, permukaan halus, dan tampak segar tanpa adanya tanda kerusakan. Kondisi ini mencerminkan jeruk dengan kualitas

terbaik. Setiap gambar disimpan dalam format JPG dan telah distandarisasi untuk kebutuhan proses lanjutan pada tahap *preprocessing*. Variasi visual yang ada sangat penting agar model dapat mengenali ciri khas dari masing-masing kelas.

### B. Teknik *Preprocessing* Data

Proses *preprocessing* memberikan peningkatan pada konsistensi serta kualitas input yang diberikan kepada model. Data citra ukurannya akan diubah menjadi 300×300 piksel berlabel format biner yang dinormalisasi pada rentang nilai [0,1]. Penerapan teknik augmentasi data seperti rotasi secara acak, pembalikan horizontal, dan pembesaran (*zooming*) efektif dalam meningkatkan keragaman citra tanpa mengurangi informasi penting dikandungnya. Hasil augmentasi disajikan Gambar 5, menunjukkan citra setelah melewati proses *preprocessing*.




Gambar 5. Hasil *Preprocessing* Citra

Contoh augmentasi dataset dapat dilihat pada Gambar 5, menampilkan berbagai variasi citra setelah melalui tahap *preprocessing*. Augmentasi seperti rotasi, *flipping*, dan *zooming* ini bertujuan memperkaya keragaman data sehingga model dapat belajar dari berbagai kondisi visual yang berbeda dan meningkatkan kemampuan generalisasi saat pengujian.

### C. Implementasi dan Konfigurasi Arsitektur VGG-16

Struktur dasar dari model pra-latih (*pretrained*) yang diperoleh dari *ImageNet* dimanfaatkan sebagai ekstraktor fitur, kemudian ditambahkan lapisan klasifikasi pada bagian atasnya. Lapisan ini mencakup satu lapisan dense dengan 256 unit neuron, *dropout* sebesar 0,5, serta satu neuron *output* yang menggunakan fungsi aktivasi sigmoid. Proses kompilasi algoritma optimisasi Adam dan fungsi *loss binary cross-entropy*. Struktur lapisan pada model VGG-16 ditunjukkan pada Gambar 6 di bawah ini.



Gambar 6. Layer Konfigurasi Arsitektur VGG-16

Pada Gambar 6 struktur lapisan diterapkan terdiri atas sejumlah blok konvolusional bertingkat yang berperan dalam mengekstraksi representasi visual secara mendalam, kemudian dilanjutkan dengan lapisan *fully connected* yang bertugas melakukan proses klasifikasi berdasarkan fitur yang telah diperoleh. Penyesuaian dilakukan pada lapisan akhir model dapat mengklasifikasikan tiga kelas, yaitu jeruk segar, mentah, dan jeruk busuk.



#### D. Hasil Pelatihan Model

Selama proses pelatihan yang berlangsung selama 99 *epoch*, model menunjukkan pola konvergensi yang stabil. Hasil akurasi dan nilai loss selama proses pelatihan menunjukkan bahwa model berhasil mencapai tingkat akurasi pelatihan sekitar 97%, sementara akurasi pada data validasi tetap stabil di angka sekitar 95%. Berkat penggunaan dropout dan strategi *early stopping*, tidak ditemukan indikasi *overfitting* yang berarti selama proses pelatihan. Kinerja model mengalami peningkatan bertahap sejak *epoch* awal, hingga mencapai performa terbaik pada *epoch* ke-84. Setelah proses pelatihan selesai, model kemudian diterapkan ke dalam aplikasi berbasis web menggunakan *framework* Flask, seperti ditampilkan pada Gambar 7.



Gambar 7. Landing Page Home Screen Untuk Informasi

Pada Gambar 7 memperlihatkan halaman utama atau *landing page* dari aplikasi web yang berfungsi sebagai halaman pembuka dengan informasi umum mengenai tujuan dan fungsi sistem deteksi kualitas jeruk berbasis VGG-16. Halaman ini juga dapat menyertakan panduan penggunaan serta informasi tambahan dapat pengguna memahami aplikasi secara menyeluruh.



Gambar 8. Halaman Upload Image dan Menampilkan Hasil Deteksi

Pada Gambar 8 telah memperlihatkan halaman unggah foto, yang merupakan fitur utama dari aplikasi. Pada halaman ini, pengguna dapat mengupload gambar jeruk untuk dilakukan analisis kualitas secara otomatis. Setelah gambar diunggah, sistem secara otomatis memproses dan menjalankan model VGG-16 untuk mengklasifikasikan jeruk sebagai segar atau busuk, kemudian menampilkan hasil deteksi secara *real-time*. Implementasi berbasis web yang dikembangkan menggunakan *framework* Flask ini memungkinkan integrasi model *machine learning* ke dalam aplikasi nyata yang dapat diakses dengan mudah melalui berbagai perangkat. Dengan demikian, aplikasi ini tidak hanya bermanfaat untuk tujuan penelitian, namun juga

berpotensi diterapkan secara praktis di lapangan, misalnya untuk pemeriksaan mutu jeruk secara cepat dan efisien oleh petani maupun pelaku industri pangan.


#### E. Evaluasi Model Terhadap Data Uji

Tabel 1 dalam rangka mengevaluasi kinerja model, disajikan matriks kebingungan (*confusion matrix*) yang diperoleh dari pengujian menggunakan data dengan tiga kelas kualitas jeruk, yaitu Segar, Mentah, dan Busuk. Matriks ini menggambarkan performa model dengan menunjukkan jumlah prediksi yang tepat maupun yang keliru untuk masing-masing kelas. Berdasarkan tabel tersebut, dapat dilihat bahwa seluruh sampel pada data uji berhasil diklasifikasikan dengan benar oleh model, di mana jumlah prediksi akurat untuk kelas Segar, Mentah, dan Busuk masing-masing mencapai 1280 sampel. Tidak terdapat prediksi salah (nilai nol pada elemen selain diagonal utama), menandakan model mampu melakukan klasifikasi dengan akurasi sempurna pada dataset uji yang digunakan. Temuan ini menunjukkan bahwa model VGG-16 yang telah dilatih mampu membedakan ketiga kelas mutu jeruk secara sangat efektif tanpa kesalahan antar kelas. Matriks kebingungan tersebut merupakan indikator utama dalam menilai kualitas dan keandalan sistem klasifikasi yang dikembangkan.

Tabel 1. Confusion Matrix Evaluation

<i>Fruit Class</i>	Inspeksi Kualitas Buah Jeruk		
	Segar	Mentah	Busuk
Segar	1280	0	0
Mentah	0	1280	0
Busuk	0	0	1280

Penilaian akhir terhadap data uji dilakukan guna mengevaluasi kemampuan generalisasi model terhadap data baru yang tidak digunakan selama proses pelatihan. Berdasarkan hasil pengujian tersebut, model menunjukkan performa yang unggul dengan akurasi sebesar 94%, presisi mencapai 95%, *recall* sebesar 93%, serta nilai *F1-score* sebesar 94%. Tabel 1 memperlihatkan matriks kebingungan yang menunjukkan bahwa sebagian kecil kesalahan klasifikasi terjadi ketika model mengidentifikasi jeruk busuk sebagai jeruk segar, meskipun kejadian ini tergolong jarang. Hasil ini mengindikasikan bahwa model memiliki akurasi dan stabilitas yang tinggi dalam melakukan klasifikasi, meskipun masih terdapat ruang untuk perbaikan, seperti melalui penambahan keragaman data atau penerapan pendekatan ensemble learning. Perbandingan kinerja antara model berbasis arsitektur VGG standar dan versi VGG-16 yang telah dimodifikasi juga ditampilkan untuk menilai efektivitas perubahan arsitektur.




Gambar 9. Nilai Akurasi Arsitektur VGG

Pada Gambar 9 memperlihatkan nilai akurasi dari model VGG sederhana yang digunakan sebagai baseline pada penelitian ini. Model ini memberikan gambaran awal tentang kemampuan klasifikasi tanpa adanya modifikasi arsitektur yang signifikan. Dari grafik tersebut, terlihat bahwa



akurasi model VGG masih terbatas dan belum mencapai performa maksimal untuk dataset jeruk yang digunakan.



Gambar 10. Peningkatan Nilai Akurasi Model VGG-16

Sementara itu, Gambar 10 memperlihatkan peningkatan signifikan pada nilai akurasi setelah penerapan arsitektur VGG-16 yang telah disesuaikan dan dioptimalkan khusus untuk tugas klasifikasi kualitas jeruk. Modifikasi pada lapisan akhir dan strategi pelatihan yang tepat memungkinkan model ini untuk menangkap fitur-fitur yang lebih kompleks dan representatif dari citra jeruk segar maupun busuk. Perbandingan kedua model ini menegaskan bahwa penggunaan arsitektur VGG-16 memberikan kontribusi signifikan dalam meningkatkan performa klasifikasi secara keseluruhan. Hal ini sekaligus membuktikan efektivitas penggunaan model pretrained yang di-*fine-tune* pada domain pengenalan kualitas buah, sehingga menghasilkan akurasi dan reliabilitas yang lebih tinggi.

#### IV. KESIMPULAN

Penelitian ini membuktikan bahwa penerapan model VGG-16 dalam klasifikasi mutu jeruk menghasilkan performa yang sangat baik dengan tingkat akurasi yang tinggi dalam membedakan kategori jeruk segar, mentah, dan busuk. Melalui penerapan strategi augmentasi data dan pendekatan transfer learning, penyesuaian arsitektur VGG-16 berhasil menghasilkan peningkatan kinerja model yang signifikan. Analisis hasil menunjukkan bahwa model hasil modifikasi memberikan performa yang lebih baik jika dibandingkan dengan versi asli dari arsitektur VGG. Evaluasi yang dilakukan menunjukkan bahwa model mampu mengklasifikasikan data uji dengan ketepatan yang konsisten dan hampir mendekati sempurna, yang menegaskan keunggulan pendekatan deep learning dalam domain klasifikasi citra buah. Penerapan sistem berbasis web dengan memanfaatkan framework Flask turut memberikan peluang bagi pengembangan aplikasi praktis yang mudah diakses secara luas, serta mendukung proses inspeksi kualitas jeruk secara waktu nyata (*real-time*) oleh petani maupun pelaku industri pangan. Dengan demikian, hasil penelitian ini memberikan kontribusi penting bagi pengembangan teknologi kecerdasan buatan di bidang teknik industri dan ilmu komputer, khususnya dalam optimalisasi proses inspeksi mutu produk agrikultur melalui pengolahan citra digital. Penelitian ini juga membuka ruang untuk pengembangan lanjutan dalam penerapan model deep learning guna meningkatkan kualitas serta efisiensi pengendalian mutu otomatis pada sektor industri pangan.

#### DAFTAR PUSTAKA

- [1] M. T. Informatika, U. Putra, and I. Yptk, "Klasifikasi Citra Dalam Identifikasi Jeruk Nipis dan Jeruk Mandarin Menggunakan Convolutional Neural Network ( CNN ) Dan Optimalisasi Median Filter," vol. 6, no. 1, pp. 56–64, 2025.
- [2] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, "Klasifikasi

- Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network,” *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 2, p. 259, 2021, doi: 10.35314/isi.v6i2.2104.
- [3] T. Sistem, “Informasi,” vol. 5, no. 4, pp. 213–218, 2024, doi: 10.62527/jitsi.5.
  - [4] R. Soekarta, N. Nurdjan, and A. Syah, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN),” *Insect (Informatics Secur. J. Tek. Inform.*, vol. 8, no. 2, pp. 143–151, 2023.
  - [5] M. S. Hawibowo and I. Muhimmmah, “Aplikasi Pendeteksi Tingkat Kematangan Pepaya menggunakan Metode Convolutional Neural Network (CNN) Berbasis Android,” *J. Edukasi dan Penelit. Inform.*, vol. 10, no. 1, p. 162, 2024, doi: 10.26418/jp.v10i1.77819.
  - [6] T. Anita and R. Ramadhani, “Analisis Perbandingan VGG-16 dan ResNet50 untuk Klasifikasi Multilabel Gambar Kerbau Toraja : Pendekatan Deep Learning,” vol. 22, no. 2, pp. 71–81, 2024.
  - [7] D. Rika Widianita, “IMPLEMENTASI VISUAL GEOMETRY GROUP (VGG19) UNTUK MENGENALI POLA CITRA DALAM MENDETEKSI PENYAKIT MATA KATARAK,” *AT-TAWASSUTH J. Ekon. Islam*, vol. VIII, no. I, pp. 1–19, 2023.
  - [8] E. S. Giamiko and E. L. Tjiong, “Pengembangan Aplikasi Pengenalan Tulisan Tangan Abjad dan Angka Berbasis Convolutional Neural Network,” vol. 11, no. 02, pp. 22–30, 2024.
  - [9] I. Elzandy *et al.*, “KLASIFIKASI VARIETAS ANGGUR BERDASARKAN CITRA DAUN MENGGUNAKAN VGG16-XGBOOST,” vol. 9, no. 3, pp. 5483–5491, 2025.
  - [10] J. Christian and S. I. Al Idrus, “Introduction to Citrus Fruit Ripens Using the Deep Learning Convolutional Neural Network (CNN) Learning Method,” *Asian J. Appl. Educ.*, vol. 2, no. 3, pp. 459–470, 2023, doi: 10.55927/ajae.v2i3.5003.
  - [11] I. Syaputra, R. Syafitri Lubis, and H. Cipta, “Pengklasifikasian Kualitas Buah Jeruk Dengan Menerapkan Metode Fuzzy K-Nearest Neighbor,” *J. Marit. Educ.*, vol. 4, no. 1, pp. 368–371, 2022, doi: 10.54196/jme.v4i1.72.
  - [12] S. A. E. ALBAKIA and R. A. Saputra, “Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16,” *J. Inform. Polinema*, vol. 9, no. 4, pp. 451–460, 2023, doi: 10.33795/jip.v9i4.1420.
  - [13] Y. A. Suwitono and F. J. Kaunang, “Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras,” *J. Komtika (Komputasi dan Inform.*, vol. 6, no. 2, pp. 109–121, 2022, doi: 10.31603/komtika.v6i2.8054.
  - [14] D. D. Kurniawati, R. Wulanningrum, and ..., “Perancangan Sistem Deteksi Penyakit Daun Jeruk Siam,” *Pros. SEMNAS ...*, vol. 7, pp. 1241–1247, 2023, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek/article/view/3564>
  - [15] J. Feriawan and D. Swanjaya, “Perbandingan Arsitektur Visual Geometry Group dan MobileNet Pada Pengenalan Jenis Kayu,” *Pros. SEMNAS INOTEK (Seminar Nas. Inov. Teknol.*, vol. 4, no. 3, pp. 185–190, 2020, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek/article/view/84>
  - [16] A. K. Ulandari, G. K. Ramdhani, W. Wahyuningsih, M. N. Arwansyuri, and F. Bimantoro, “Klasifikasi Jeruk Segar dan Busuk Melalui GLCM dan HSV dengan Menggunakan Metode ANN,” *Semin. Nas. Teknol. Sains*, vol. 3, no. 1, pp. 97–102, 2024, doi: 10.29407/stains.v3i1.4358.
  - [17] Afis Julianto, Andi Sunyoto, and Ferry Wahyu Wibowo, “Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi,” *Tek. Teknol. Inf. dan Multimed.*, vol. 3, no. 2, pp. 98–105, 2022, doi: 10.46764/teknimedia.v3i2.77.