

Pengolahan Citra Kematangan Pisang Menggunakan Convolutional Neural Network VGG19

^{1*}Gilang Dwi Cahyo, ²Risa Helilintar, ³Intan Nur Farida

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: *1evermillion921@gmail.com, 2Risa.helilintar@gmail.com, 3in.nfarida@gmail.com

Penulis Korespondens : Gilang Dwi Cahyo

Abstrak Klasifikasi tingkat kematangan buah pisang secara manual masih umum dilakukan, yang sering kali menyebabkan ketidakkonsistenan serta memerlukan waktu dan tenaga yang besar. Untuk mengatasi permasalahan ini, penelitian ini mengusulkan penggunaan metode *Convolutional Neural Network (CNN)* dengan arsitektur VGG19 yang dikenal mampu mengekstraksi fitur visual secara mendalam. Dataset yang digunakan terdiri dari 5.616 gambar pisang yang diklasifikasikan ke dalam empat kategori: mentah, matang, terlalu matang, dan busuk. Teknik augmentasi data dan pendekatan transfer learning diterapkan untuk meningkatkan performa model. Hasil pelatihan menunjukkan akurasi validasi sebesar 98% dan nilai loss kurang dari 0,07 setelah 25 epoch. Model menunjukkan kemampuan generalisasi yang baik tanpa tanda-tanda overfitting. Temuan ini mengindikasikan bahwa pendekatan CNN VGG19 efektif untuk pengembangan sistem klasifikasi kematangan pisang secara otomatis.

Kata Kunci— Akurasi, CNN, Klasifikasi, Pisang, VGG19

Abstract *Manual classification of banana ripeness is still commonly practiced, often resulting in inconsistency and requiring substantial time and effort. To address this issue, this study proposes the use of a Convolutional Neural Network (CNN) with the VGG19 architecture, which is known for its strong visual feature extraction capabilities. The dataset consists of 5,616 banana images categorized into four classes: unripe, ripe, overripe, and rotten. Data augmentation and transfer learning techniques were applied to improve model performance. The training process achieved a validation accuracy of 98% and a loss value below 0.07 after 25 epochs. The model demonstrated strong generalization without signs of overfitting. These results suggest that the CNN VGG19 approach is effective for developing an automated banana ripeness classification system.*

Keywords— accuracy, banana, classification, CNN, VGG19

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



I. PENDAHULUAN

Tanaman pisang merupakan salah satu komoditas hortikultura buah tropis yang memiliki potensi dan nilai ekonomi yang cukup tinggi. Buah ini tidak hanya kaya akan vitamin dan mineral, tetapi juga mampu memberikan energi lebih baik dibandingkan beberapa jenis buah lainnya. Berbagai manfaat yang dimiliki pisang menjadikannya memiliki peran penting dalam berbagai aspek, antara lain sebagai sumber pangan, menjaga kesehatan, mendukung nilai sosial budaya, serta memberikan kontribusi terhadap sektor ekonomi [1]. Dalam proses distribusi dan konsumsi buah pisang, pemisahan berdasarkan tingkat kematangan menjadi langkah penting untuk memastikan kualitas dan kepuasan konsumen. Namun, proses tersebut masih banyak dilakukan secara manual, sehingga membutuhkan waktu dan tenaga yang cukup besar. Selain itu, perbedaan persepsi visual antar individu terhadap tingkat kematangan dapat menyebabkan hasil klasifikasi

yang tidak konsisten. Untuk mengatasi permasalahan tersebut, dibutuhkan sebuah sistem otomatis yang mampu mengidentifikasi dan mengklasifikasikan tingkat kematangan buah pisang secara akurat dan efisien. Salah satu metode yang dapat digunakan untuk mewujudkan sistem tersebut adalah Convolutional Neural Network (CNN) [2].

Hasil penelitian oleh [3] yang membahas tentang *“Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network Dengan Transfer Learning Xception”* berhasil membangun model klasifikasi kematangan buah kelapa sawit menggunakan arsitektur *Xception* dan teknik *augmentasi data*, yang mampu mencapai tingkat akurasi sebesar 90%, dengan pembagian data latih dan uji sebesar 85:15. Capaian ini membuktikan bahwa CNN merupakan pendekatan yang efektif dalam pengolahan *citra digital* untuk klasifikasi objek visual. Penelitian lain [4] yang membahas tentang *“Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3”* menunjukkan bahwa metode *CNN Inception V3* mampu mengidentifikasi tingkat kematangan buah kopi kuning secara efektif, menghasilkan akurasi klasifikasi sebesar 92% pada tahap pengujian. Hasil penelitian [5] yang membahas tentang *“Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN”* menunjukkan bahwa metode *Convolutional Neural Network (CNN)* mampu mengklasifikasikan tingkat kematangan buah mangga dengan akurasi yang sangat tinggi, yaitu mencapai 97,2% pada data pengujian.

Penelitian lain [6] yang membahas tentang *“Deteksi Tingkat Kematangan Buah Pepaya Menggunakan Model Convolutional Neural Network”* menunjukkan bahwa model *Convolutional Neural Network (CNN)* yang dibangun mampu mendekripsi tingkat kematangan buah pepaya dengan akurasi tertinggi mencapai 96,63%, menggunakan arsitektur 3 *layer convolutional* dan *optimizer Nadam*. Model tersebut berhasil mengklasifikasikan buah pepaya ke dalam tiga kategori yaitu mentah, setengah matang, dan matang dengan tingkat *presisi* dan *recall* yang tinggi, serta menunjukkan performa lebih baik dibandingkan pendekatan sebelumnya seperti *YOLO*, *RGB*, dan *K-Nearest Neighbor*. Hasil penelitian lain [7] yang membahas tentang *“Klasifikasi Tingkat Kematangan Buah Pisang Menggunakan Metode CNN Arsitektur VGG19”* menunjukkan bahwa model *CNN* dengan arsitektur *VGG19* mampu mengklasifikasikan tingkat kematangan buah pisang dengan akurasi maksimal 100% pada seluruh konfigurasi yang diuji. *Dataset* yang digunakan terdiri dari 450 gambar pisang yang terbagi dalam tiga kelas, yaitu mentah, matang, dan sangat matang. Penggunaan *optimizer Adam* dengan 20 *epoch* menghasilkan performa terbaik dengan nilai *loss* terendah sebesar 0,02, sedangkan *optimizer SGD* pada *epoch* yang sama menghasilkan *loss* 0,04. Meskipun akurasi tetap konstan pada setiap konfigurasi, penggunaan *Adam* dengan *epoch* lebih tinggi terbukti lebih efektif dalam meminimalkan nilai *loss*.

Berdasarkan permasalahan di atas, penelitian ini mengusulkan penggunaan metode CNN untuk melakukan klasifikasi kematangan buah pisang berdasarkan warna. Terdapat empat kriteria yang digunakan yaitu matang, mentah, busuk, dan terlalu matang. Perbedaan penelitian ini dengan penelitian sebelumnya yang telah disebutkan yaitu menggunakan 4 kriteria, jumlah dataset dan penggunaan *epoch* yang berbeda. Penelitian ini memiliki tujuan untuk mendapatkan model dengan akurasi yang baik dalam klasifikasi kematangan buah pisang sehingga dapat memberikan kontribusi dalam pengembangan teknik klasifikasi buah pisang berdasarkan warna menggunakan metode CNN Arsitektur *VGG19*.

II. METODE

A. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari platform *Roboflow*. Dataset tersebut terdiri dari 5.616 gambar buah pisang yang diklasifikasikan ke dalam empat kelas kematangan, yaitu mentah, matang, terlalu matang, dan busuk. Gambar-gambar ini diambil dengan variasi latar belakang, pencahayaan, serta posisi objek yang berbeda-beda untuk meningkatkan keanekaragaman data. Contoh dataset yang digunakan ditampilkan pada Gambar 1:



Gambar 1. Dataset Pisang

B. Pembagian Dataset

Setelah dikumpulkan, *dataset* dibagi menjadi tiga bagian, yaitu 70% untuk data pelatihan (*training*), 20% untuk data validasi (*validation*), dan 10% untuk data pengujian (*testing*). Pembagian ini dilakukan untuk memastikan bahwa model yang dilatih dapat dievaluasi dengan data yang belum pernah dilihat sebelumnya.

C. Augmentasi Data

Augmentasi data pada penelitian ini dilakukan menggunakan *library ImageDataGenerator*. *Library* tersebut menyediakan berbagai parameter untuk *augmentasi*, dan dalam penelitian ini digunakan parameter “*zoom_range=0.2*”. Setelah parameter diterapkan, proses *augmentasi* dilakukan pada data gambar untuk *training* dan *validasi*. Pada proses *training*, digunakan parameter “*target_size=(100, 100)*” dan “*color_mode='rgb'*” dalam metode “*flow*”.

D. Perancangan Arsitektur CNN (VGG19)

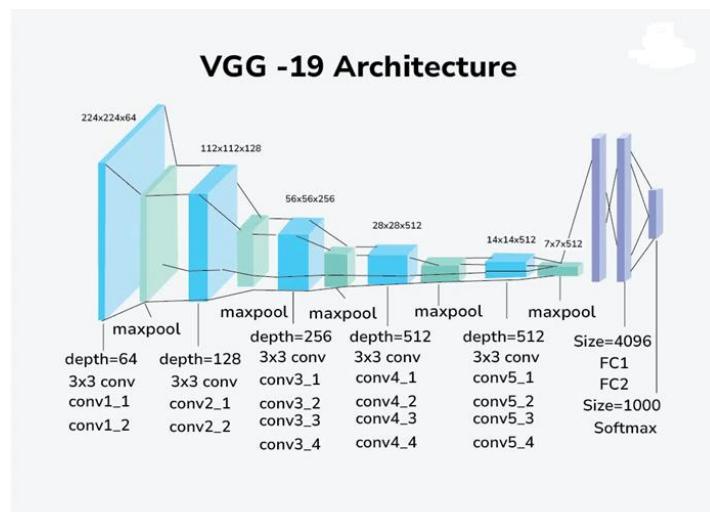
Convolutional Neural Network (CNN) merupakan salah satu arsitektur *deep learning* yang dirancang khusus untuk mengolah data berbentuk *grid*, seperti gambar dua dimensi. Arsitektur ini terinspirasi dari cara kerja korteks visual pada otak manusia, di mana neuron-neuron merespons rangsangan pada wilayah reseptif tertentu. Mekanisme tersebut direplikasi dalam *CNN* melalui lapisan-lapisan *konvolusi* yang memungkinkan model mengekstraksi fitur-fitur lokal dari data *input*. Lapisan ini terdiri dari *filter* atau *kernel* yang bergerak melintasi *input*

untuk menghasilkan *feature map*, yang kemudian diproses lebih lanjut oleh lapisan *pooling* untuk mereduksi dimensi, dan dilanjutkan ke lapisan *fully connected* guna menghasilkan *output* akhir. Keunggulan utama *CNN* terletak pada kemampuannya dalam mengenali pola-pola kompleks pada data visual dengan efisiensi parameter yang tinggi, sehingga sangat efektif untuk berbagai tugas seperti *klasifikasi gambar*, *deteksi objek*, dan *segmentasi citra*. Kemampuannya tersebut membuat *CNN* berhasil diterapkan secara luas di berbagai bidang, termasuk *analisis citra medis* dan *sistem pengawasan*, yang menunjukkan fleksibilitas serta efektivitas model ini dalam menangani beragam permasalahan visual [8].

Selain itu, *CNN* juga terbukti mampu memberikan hasil yang akurat dalam pengenalan pola visual, khususnya pada aplikasi pengolahan citra di bidang medis dan pertanian, berkat kemampuannya dalam menyesuaikan bobot-bobot secara dinamis berdasarkan pola data yang dipelajari secara mendalam [9]. *VGG19* merupakan salah satu arsitektur *Convolutional Neural Network (CNN)* yang dikembangkan oleh *Visual Geometry Group* dari *University of Oxford*. Arsitektur ini terdiri dari 19 lapisan yang dapat dilatih, termasuk 16 lapisan *konvolusi* dan 3 lapisan *fully connected*. Ciri khas *VGG19* adalah penggunaan *filter konvolusi* berukuran 3×3 secara berurutan, yang memungkinkan model untuk mengekstraksi fitur kompleks dari citra melalui kedalaman jaringan yang tinggi. Lapisan *pooling* digunakan setelah beberapa blok *konvolusi* untuk mereduksi dimensi spasial dari *feature map*, sementara lapisan *fully connected* berfungsi untuk klasifikasi akhir. Keunggulan utama *VGG19* terletak pada struktur arsitekturnya yang konsisten dan dalam, sehingga memudahkan implementasi serta adaptasi ke berbagai tugas klasifikasi citra.

Dalam penelitian oleh Jamshidi dan Rostamy-Malkhalifeh [10], *VGG19* digunakan untuk mendiagnosis dan mengklasifikasikan tumor otak berdasarkan citra *MRI*. Model ini, yang dikombinasikan dengan pendekatan *transfer learning* dan *artificial neural network (ANN)*, berhasil mencapai akurasi keseluruhan sebesar 91,26% dalam klasifikasi tumor otak menjadi empat kelas: *meningioma*, *glioma*, *pituitari*, dan tanpa tumor. Studi ini menunjukkan efektivitas *VGG19* dalam aplikasi medis, khususnya dalam analisis citra *MRI* untuk deteksi tumor otak. Selain itu, dalam penelitian oleh Sudha dan Ganeshbabu [11], *VGG19* diterapkan untuk mendeteksi dan mengklasifikasikan lesi pada *retinopati diabetik* menggunakan citra *fundus*. Dengan memanfaatkan *transfer learning* dan teknik reduksi dimensi seperti *PCA (Principal Component Analysis)* dan *SVD (Singular Value Decomposition)*, model ini berhasil meningkatkan akurasi klasifikasi dan efisiensi komputasi. Hasil penelitian ini menegaskan bahwa *VGG19* dapat diadaptasi secara efektif untuk berbagai aplikasi pengolahan citra medis, termasuk dalam deteksi penyakit mata.

Penelitian ini menggunakan model *VGG19* sebagai dasar arsitektur *CNN* dengan pendekatan *transfer learning*. Model *VGG19* dimanfaatkan sebagai *feature extractor* dengan menghapus lapisan klasifikasi bawaan melalui pengaturan *include_top=False*. Selanjutnya, arsitektur dimodifikasi dengan menambahkan beberapa lapisan tambahan pada bagian akhir jaringan untuk disesuaikan dengan kebutuhan klasifikasi empat kelas kematangan pisang. Gambar dari arsitektur *VGG19* dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur VGG19

Gambar 2 menunjukkan struktur dari *VGG19*, di mana setiap lapisan memiliki peran tersendiri dalam proses ekstraksi fitur. Pada penelitian ini, beberapa lapisan tambahan ditambahkan untuk mendukung klasifikasi empat kelas kematangan. Pertama, ditambahkan *Flatten layer* yang berfungsi untuk mengubah keluaran dari lapisan konvolusi terakhir menjadi bentuk vektor satu dimensi. Kemudian, ditambahkan *Dense layer* sebanyak 256 unit dengan fungsi aktivasi *ReLU* guna membentuk hubungan non-linear antar fitur. Selanjutnya, diterapkan *Dropout layer* dengan nilai 0.5 untuk mengurangi *overfitting* dengan mengabaikan sebagian neuron secara acak selama pelatihan. Terakhir, ditambahkan *Dense output layer* sebanyak 4 unit dengan fungsi aktivasi *Softmax* untuk menghasilkan keluaran dalam bentuk probabilistik terhadap masing-masing kelas kematangan, yaitu mentah, matang, terlalu matang, dan busuk.

E. Komplikasi dan Pelatihan Model

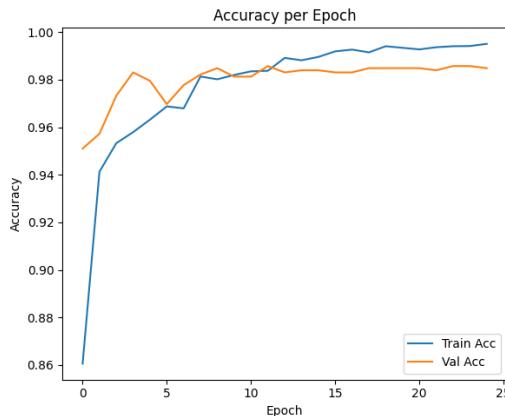
Setelah melalui proses yang ada di arsitektur VGG19 selanjutnya model akan dikompilasi menggunakan *loss function categorical crossentropy*, *optimizer Adam*, dan metrik *accuracy*. Proses pelatihan dilakukan selama 20 *epoch* dengan batch size 32 menggunakan fungsi “*model.fit()*”. Selama proses ini, model dilatih menggunakan data training dan divalidasi dengan data validasi.

F. Evaluasi Model

Setelah proses pelatihan selesai dilakukan, langkah selanjutnya adalah menguji model menggunakan data yang telah disiapkan untuk pengujian. Pengujian ini bertujuan untuk mengevaluasi sejauh mana model mampu mengenali dan mengklasifikasikan tingkat kematangan pisang berdasarkan fitur visual pada gambar. Proses ini penting untuk memastikan bahwa model tidak hanya bekerja baik pada data pelatihan, tetapi juga mampu menggeneralisasi dengan baik terhadap data baru. Dengan demikian, performa model dapat dinilai secara menyeluruh sebelum diterapkan dalam situasi nyata atau sistem produksi.

III. HASIL DAN PEMBAHASAN

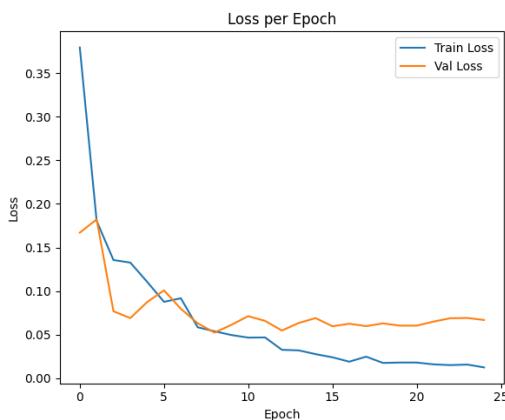
Penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan buah pisang ke dalam empat kelas, yaitu mentah, matang, terlalu matang, dan busuk, menggunakan arsitektur CNN VGG-19. Model dilatih menggunakan dataset yang telah diaugmentasi dengan berbagai parameter, dan hasil pelatihan dievaluasi melalui grafik akurasi dan loss per *epoch*.



Gambar 3. Grafik Akurasi per *epoch*

Gambar 3 menunjukkan grafik akurasi pelatihan dan validasi per *epoch* selama 25 iterasi pelatihan. Terlihat bahwa akurasi data pelatihan meningkat secara signifikan sejak awal, dari sekitar 86% pada *epoch* pertama hingga mendekati 99% pada *epoch* ke-25. Sementara itu, akurasi validasi juga menunjukkan tren positif, mencapai puncaknya sekitar 98%, dan stabil pada nilai tersebut setelah melewati *epoch* ke-10.

Performa akurasi yang tinggi ini menunjukkan bahwa model mampu mempelajari karakteristik citra dengan baik tanpa kehilangan kemampuan generalisasi. Tidak terdapat perbedaan signifikan antara akurasi pelatihan dan validasi, yang menandakan tidak terjadi overfitting secara ekstrem

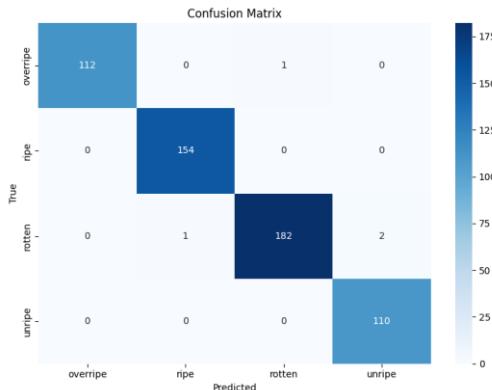


Gambar 4. Grafik Loss per *Epoch*

Gambar 4 menunjukkan grafik nilai loss untuk data pelatihan dan validasi. Loss pelatihan turun drastis dari sekitar 0.37 menjadi kurang dari 0.02 pada akhir pelatihan. Loss validasi juga menurun secara signifikan di awal, namun cenderung fluktuatif di tengah pelatihan dan stabil setelah *epoch* ke-10, dengan nilai berkisar antara 0.04 hingga 0.07.

Fenomena ini mengindikasikan bahwa model dengan optimizer dan konfigurasi saat ini mampu menurunkan fungsi kerugian secara konsisten. Penurunan loss yang signifikan,

terutama pada data pelatihan, menunjukkan bahwa proses pembelajaran terjadi secara optimal. Sementara fluktuasi ringan pada loss validasi menunjukkan tantangan dalam generalisasi penuh, namun nilainya tetap dalam batas toleransi



Gambar 5. Confusion Matrix

Gambar 5 menunjukkan confusion matrix dari hasil pengujian model terhadap data uji. Berdasarkan visualisasi tersebut, terlihat bahwa model mampu mengklasifikasikan keempat kelas kematangan buah pisang dengan sangat baik. Kelas *ripe* dan *unripe* berhasil diklasifikasikan secara sempurna tanpa kesalahan prediksi. Sementara itu, kelas *overripe* diklasifikasikan hampir sempurna, dengan hanya satu gambar yang salah terklasifikasi sebagai *rotten*. Pada kelas *rotten*, sebagian besar prediksi juga tepat, dengan hanya satu gambar salah diklasifikasikan sebagai *ripe* dan dua gambar sebagai *unripe*. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dan mampu membedakan ciri visual antar kelas secara akurat, bahkan pada kelas yang secara visual memiliki kemiripan seperti *overripe* dan *rotten*. Dengan jumlah kesalahan yang sangat kecil, dapat disimpulkan bahwa model VGG19 yang digunakan sangat efektif dalam tugas klasifikasi kematangan buah pisang.

Tabel 1. Ringkasan Performa Model Setiap 5 Epoch

Epoch	Akurasi Training	Akurasi Validasi	Loss Training	Loss Validasi
1	0.860	0.952	0.370	0.180
5	0.968	0.970	0.100	0.070
10	0.981	0.983	0.055	0.067
15	0.987	0.983	0.027	0.059
20	0.990	0.982	0.017	0.063
25	0.992	0.981	0.012	0.067

Tabel 1 menampilkan ringkasan performa model setiap lima *epoch* berdasarkan grafik akurasi dan *loss*. Pada *epoch* pertama, model memulai pelatihan dengan akurasi *training* sebesar 86% dan akurasi validasi 95,2%, dengan nilai *loss* yang relatif tinggi yaitu 0,37 untuk *training* dan 0,18 untuk validasi. Seiring bertambahnya *epoch*, performa model terus meningkat. Akurasi *training* mencapai 99,2% pada epoch ke-25, sedangkan akurasi validasi stabil di kisaran 98%. *Loss training* menunjukkan penurunan signifikan hingga 0,012, sedangkan *loss validasi* sempat mengalami fluktuasi kecil namun tetap berada dalam rentang yang rendah. Hal ini menunjukkan bahwa model belajar dengan baik tanpa *overfitting* yang berarti. Tren ini

memperkuat kesimpulan bahwa arsitektur VGG19 dengan pendekatan *transfer learning* sangat efektif dalam mengklasifikasikan tingkat kematangan buah pisang.

Analisis dan Diskusi Model CNN dengan arsitektur VGG19 menunjukkan performa yang sangat baik dalam mengklasifikasikan tingkat kematangan pisang. Akurasi yang tinggi dan loss yang rendah pada kedua dataset menjadi bukti bahwa struktur lapisan *konvolusi* dan *fully connected* yang digunakan cukup efektif dalam mengekstraksi dan mengklasifikasikan fitur dari citra buah pisang.

Jika dibandingkan dengan penelitian sebelumnya yang menggunakan tiga kelas dan dataset berjumlah 450 gambar, hasil penelitian ini menunjukkan performa yang tidak jauh berbeda meskipun menggunakan empat kelas dengan jumlah data yang lebih besar. Hal ini membuktikan bahwa model VGG19 dapat diskalakan untuk klasifikasi dengan lebih banyak kelas tanpa menurunkan akurasi secara signifikan.

Namun, perlu dicatat bahwa fluktuasi kecil pada loss validasi dapat menjadi indikasi bahwa proses pelatihan masih dapat ditingkatkan, misalnya dengan pengaturan hiperparameter lebih lanjut atau penambahan teknik regularisasi seperti dropout.

IV. KESIMPULAN

Penelitian ini berhasil membangun model klasifikasi tingkat kematangan buah pisang menggunakan arsitektur CNN VGG19 dengan pendekatan transfer learning. Model ini dikembangkan untuk mengenali empat kategori kematangan, yaitu mentah, matang, terlalu matang, dan busuk. Berdasarkan hasil pelatihan selama 25 *epoch*, model menunjukkan akurasi validasi hingga 98% dengan nilai loss yang rendah dan stabil, mengindikasikan performa generalisasi yang baik tanpa overfitting yang signifikan. Hasil ini membuktikan bahwa arsitektur VGG19 efektif untuk tugas klasifikasi citra buah pisang dan layak dijadikan dasar pengembangan sistem klasifikasi otomatis dalam bidang pertanian dan industri pengolahan buah. Ke depan, pengembangan dapat difokuskan pada pengujian dengan data dunia nyata serta eksplorasi pengaturan hiperparameter yang lebih optimal untuk meningkatkan akurasi dan efisiensi sistem.

DAFTAR PUSTAKA

- [1] M. P. S. Staf *et al.*, “Potensi Pengembangan Tanaman Pisang : Tinjauan Syarat Tumbuh dan Teknik Budidaya Pisang Dengan Metode Bit,” *Jurnal Ilmiah Agrosaint*, vol. 12, no. 2, 2021.
- [2] P. Adi Nugroho, I. Fenriana, and R. Arijanto, “IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA,” *JURNAL ALGOR*, vol. 2, no. 1, 2020, [Online]. Available: <https://jurnal.buddhidharma.ac.id/index.php/ALGOR/index>
- [3] I. Afandy, B. N. Ahmad, and M. R. Amarharizqi, “Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network (CNN) Dengan Transfer Learning Xception,” *Jurnal Ilmiah Teknologi Informasi dan Robotika*, vol. 6, no. 2, pp. 88–98, Dec. 2024, doi: 10.33005/jifti.v6i2.158.
- [4] U. UNGKAWA and G. AL HAKIM, “Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3,” *ELKOMIKA: Jurnal Teknik Energi*

Elektrik, Teknik Telekomunikasi, & Teknik Elektronika, vol. 11, no. 3, p. 731, Jul. 2023, doi: 10.26760/elkomika.v11i3.731.

- [5] S. A. Damayanti, A. Arkadia, and D. S. Prasvita, “Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN,” in *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya*, 2021, pp. 158–165.
- [6] N. P. Sutrisna *et al.*, “Deteksi Tingkat Kematangan Buah Pepaya menggunakan Model Convolutional Neural Network,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 3, pp. 569–578, Jul. 2024, doi: 10.25126/jtiik.938119.
- [7] F. A. Haq, M. Kurniawan, M. A. Wicaksono, and P. S. Alala, “Klasifikasi Tingkat Kematangan Buah Pisang Menggunakan Metode Cnn Arsitektur Vgg19,” *Jurnal Tika*, vol. 9, no. 2, pp. 131–136, 2024.
- [8] D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Analisis Citra Medis,” 2022.
- [9] A. L. Sigit Gunthoro, E. Julianto, and D. Budiyanto, “Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network.”
- [10] B. Jamshidi and M. Rostamy-Malkhalifeh, “Using VGG19 Transfer Learning to Diagnose and Classify Brain Tumors Based on CNN, and Predict with Deep Learning-Based ANN Transfer Learning via MR Images,” *SSRN Electronic Journal*, 2023, doi: 10.2139/ssrn.4624936.
- [11] V. Sudha and T. R. Ganeshbabu, “A convolutional neural network classifier VGG-19 architecture for lesion detection and grading in diabetic retinopathy based on deep learning,” *Computers, Materials and Continua*, vol. 66, no. 1, pp. 827–842, 2021, doi: 10.32604/cmc.2020.012008.