

# Deteksi Kualitas Pisang Kepok Berbasis Citra Digital Menggunakan CNN dengan Ruang Warna HSV

<sup>1\*</sup>Muhammad Qoyyum, <sup>2</sup>Wahyu Cahyo Utomo, <sup>3</sup>Danang Wahyu Widodo

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

E-mail: <sup>1</sup>[muhammadqoyyum2003@gmail.com](mailto:muhammadqoyyum2003@gmail.com), <sup>2</sup>[wahyu.utomo@unpkdr.ac.id](mailto:wahyu.utomo@unpkdr.ac.id), <sup>3</sup>[danangwahyuwidodo@unpkediri.ac.id](mailto:danangwahyuwidodo@unpkediri.ac.id)

**Penulis Korespondens : Muhammad Qoyyum**

**Abstrak**— Pisang kepok (*Musa acuminata* × *balbisiana*) merupakan komoditas hortikultura bernilai ekonomi tinggi yang kualitasnya masih dinilai secara manual dan subjektif. Penelitian ini mengembangkan sistem deteksi kualitas pisang kepok berbasis citra digital menggunakan metode *Convolutional Neural Network* (CNN) dengan ruang warna HSV (*Hue, Saturation, Value*). Dataset terdiri dari 406 citra pisang kepok yang dibagi ke dalam tiga kelas: Grade A (Matang), Grade B (Terlalu Matang), dan Grade C (Belum Matang). Model CNN dibangun dengan tiga lapisan konvolusi (filter 16, 32, 64), satu lapisan *Dense 64 neuron*, dan *Dropout* 0,4, kemudian dilatih menggunakan *optimizer Adam* dengan learning rate 0,0001 dan ukuran input 224×224 piksel. *Preprocessing* mencakup konversi ruang warna BGR ke HSV, perbaikan saturasi dengan *histogram equalization*, normalisasi piksel, dan augmentasi data. Proses pelatihan berhenti pada epoch ke-18 berkat mekanisme *Early Stopping*, dengan bobot terbaik diperoleh pada epoch ke-13. Hasil evaluasi menunjukkan bahwa model CNN-HSV mencapai akurasi sebesar 92,68% dan *loss* 0,2104 pada data pengujian. Penelitian ini membuktikan bahwa ruang warna HSV efektif untuk deteksi kualitas pisang kepok berbasis citra digital karena kemampuannya memisahkan informasi kromatik dari luminansi sehingga lebih stabil terhadap variasi pencahayaan.

**Kata Kunci**— Augmentasi Data, Citra Digital, CNN, *Early Stopping*, HSV, Pisang Kepok

**Abstract**—Kepok banana (*Musa acuminata* × *balbisiana*) is a horticultural commodity with high economic value whose quality is still assessed manually and subjectively. This study developed a digital image-based kepok banana quality detection system using the *Convolutional Neural Network* (CNN) method with the HSV (*Hue, Saturation, Value*) color space. The dataset consists of 406 kepok banana images divided into three classes: Grade A (Ripe), Grade B (Overripe), and Grade C (Unripe). The CNN model was built with three convolutional layers (filters 16, 32, 64), one Dense layer of 64 neurons, and Dropout of 0.4, then trained using the Adam optimizer with a learning rate of 0.0001 and an input size of 224×224 pixels. Preprocessing includes BGR-to-HSV color space conversion, saturation enhancement with histogram equalization, pixel normalization, and data augmentation. The training process stopped at epoch 18 through *Early Stopping*, with the best weights obtained at epoch 13. Evaluation results show that the CNN-HSV model achieved an accuracy of 92,68% and a loss of 0.2104 on the test data. This study demonstrates that the HSV color space is effective for digital image-based kepok banana quality detection due to its ability to separate chromatic information from luminance, making it more stable under lighting variations..

**Keywords**— CNN, Data Augmentation, Digital Image, *Early Stopping*, HSV, Kepok Banana

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



## I. PENDAHULUAN

Pisang Pisang kepok (*Musa acuminata* × *balbisiana*) merupakan komoditas hortikultura strategis di Indonesia yang menjadi bahan baku utama industri pangan [1]. Namun, pengendalian kualitas pascapanen saat ini masih didominasi oleh pengamatan visual manual yang bersifat subjektif dan tidak konsisten [2]. Sebagai solusi, pengolahan citra digital hadir dengan memanfaatkan ruang warna HSV (*Hue, Saturation, Value*) yang terbukti lebih stabil terhadap variasi pencahayaan dibandingkan RGB karena memisahkan informasi warna dari kecerahan [3][4]. Di sisi lain, *Convolutional Neural Network* (CNN) telah terbukti efektif dalam mengekstrak fitur visual secara otomatis untuk klasifikasi kematangan buah [5][6][7], seperti yang ditunjukkan oleh Akbar et al. [8] pada aplikasi Android dan Adenugraha et al. [9] yang memadukan fitur RGB-HSV dengan KNN. Meskipun efektivitas HSV telah didokumentasikan pada berbagai komoditas seperti cabai [11], stroberi [15], dan tomat [16], penelitian yang secara khusus membangun arsitektur CNN berbasis HSV dengan perbaikan saturasi dan augmentasi data untuk kasus pisang kepok masih sangat terbatas. Berdasarkan celah (gap) tersebut, penelitian ini bertujuan membangun dan mengevaluasi model CNN berbasis ruang warna HSV untuk mengklasifikasikan kualitas pisang kepok ke dalam tiga tingkatan secara akurat: Grade A (Matang), Grade B (Terlalu Matang), dan Grade C (Belum Matang).

## II. METODE

### A. Dataset dan Pengumpulan Data

Dataset penelitian terdiri dari 406 citra pisang kepok yang dikumpulkan secara mandiri menggunakan kamera *smartphone* dengan pencahayaan seragam dan latar belakang polos. Menggunakan metode *stratified split*, dataset ini dibagi dengan rasio 80:20 menjadi data latih (324 citra) dan data uji (82 citra). Secara total, 406 citra tersebut terdistribusi hampir merata ke dalam tiga kelas, yaitu Grade A (Matang dengan kulit kuning siap konsumsi) sebanyak 135 citra, Grade B (Terlalu Matang dengan kulit kuning kecokelatan) sebanyak 136 citra, dan Grade C (Belum Matang dengan kulit hijau) sebanyak 135 citra.



Gambar 1. Dataset Pisang Kepok Grade A, B, C

Gambar 1 mengilustrasikan perbedaan visual yang signifikan pada kulit luar pisang kepok untuk masing-masing kelas target tersebut. Grade A dicirikan oleh dominasi warna kuning cerah, Grade B menunjukkan bercak cokelat kehitaman di atas warna kuning dasar akibat degradasi kematangan, sedangkan Grade C didominasi oleh warna hijau solid. Perbedaan karakteristik kromatik yang kontras inilah yang nantinya dieksplorasi secara optimal oleh ruang warna HSV.

## B. Preprocessing dan Konversi Ruang Warna HSV

Seluruh citra melalui empat tahap preprocessing: (1) pengubahan ukuran menjadi 224x224 piksel; (2) konversi ruang warna BGR ke HSV dengan fungsi `cv2.cvtColor()` dan parameter `cv2.COLOR_BGR2HSV` pada *OpenCV*; (3) perbaikan kontras melalui histogram equalization pada kanal Saturation (S) menggunakan `cv2.equalizeHist()`; serta (4) normalisasi nilai piksel ke rentang [0, 1]. Ruang warna HSV memisahkan informasi kromatik (*Hue dan Saturation*) dari luminansi (*Value*). Pemisahan ini membuat model lebih robust karena variasi intensitas cahaya hanya memengaruhi kanal V tanpa mendistorsi informasi warna asli objek [9][11]. Persamaan konversi dari RGB ke HSV dinyatakan sebagai berikut:

*Brightness (Value) is calculated from:*

$$V = \max(R, G, B) \dots \dots \dots (1)$$

*Saturation is calculated as:*


$$S = \frac{V - \min(R, G, B)}{V} \text{ (jika } V \neq 0, \text{ dan } S = 0 \text{ jika } V = 0) \dots \dots (2)$$

*Hue is calculated based on the dominant color component:*

$$H = 60^\circ \times \left( \frac{G - B}{\max(R, G, B) - \min(R, G, B)} \right) \dots \dots (3)$$

## C. Arsitektur Model CNN

Model CNN yang digunakan terdiri dari tiga blok konvolusi dan dua lapisan *fully connected*. Seluruh spesifikasi lapisan disajikan dalam penjelasan gambar 2.



Gambar 2. Arsitektur Model CNN

Berdasarkan Gambar 2, arsitektur CNN yang digunakan terdiri dari 11 lapisan sekuensial dengan input citra HSV berukuran 224x224x3. Ekstraksi fitur dilakukan melalui tiga blok konvolusi (kernel 3x3, aktivasi ReLU) dan *MaxPooling2D* (2x2). Blok pertama menggunakan Conv2D 16 filter untuk menangkap fitur tepi dan gradien warna (menghasilkan dimensi 111x111x16). Blok kedua naik menjadi 32 filter untuk mengenali pola tekstur dan kombinasi warna kematangan (54x54x32), sedangkan blok ketiga menggunakan 64 filter untuk menangkap fitur semantik abstrak (26x26x64). Selanjutnya, lapisan *Flatten* mengubah tensor menjadi vektor 1 dimensi berisi 43.264 elemen, yang diproses oleh lapisan Dense 64

neuron (ReLU) untuk integrasi fitur spasial. Guna mencegah *overfitting*, diterapkan *Dropout* dengan laju 0,4 sebelum akhirnya ditutup oleh lapisan Dense 3 neuron beraktivasi *Softmax* untuk mengklasifikasikan pisang kepok ke dalam tiga kelas akhir: Grade A (Matang), Grade B (Terlalu Matang), dan Grade C (Belum Matang)

#### D. Augmentasi Data

Augmentasi data dilakukan untuk memperbanyak variasi data latih secara artifisial, yang sangat penting untuk mencegah *overfitting* dan meningkatkan generalisasi model pada dataset berukuran sedang (406 citra) [5][6]. Teknik ini diterapkan menggunakan kelas *ImageDataGenerator* dari Keras dengan tiga parameter utama.


Transformasi rotasi pada koordinat piksel (x, y) terhadap pusat citra (cx, cy) dinyatakan sebagai:

$$x' = (x - cx)\cos\theta - (y - cy)\sin\theta + cx \dots \dots \dots (4)$$

$$y' = (x - cx)\sin\theta - (y - cy)\cos\theta + cy \dots \dots \dots (5)$$

$$x' = W - 1 - x, y' \dots \dots \dots (6)$$

Gambar 3 mengilustrasikan hasil penerapan ketiga teknik augmentasi data tersebut pada citra pisang kepok.




Gambar 3. Ilustrasi Teknik Augmentasi Data: Original, dan Flip Horizontal

Ketiga teknik augmentasi tersebut diterapkan secara *on-the-fly*, artinya setiap citra diaugmentasi secara *real-time* pada setiap iterasi pelatihan menggunakan metode *datagen.flow()* dengan *batch size* = 8. Hal ini berarti tidak ada citra augmentasi yang disimpan secara permanen ke *disk*, melainkan dihasilkan secara dinamis selama proses pelatihan berlangsung, sehingga menghemat penggunaan memori dan waktu pra-pemrosesan.

#### E. Pelatihan Model

Model Model CNN-HSV dilatih di *Google Colaboratory* (GPU) menggunakan *optimizer Adam* (*learning rate* = 0,0001) untuk pembaruan bobot yang stabil, serta fungsi *loss Categorical Cross-Entropy* untuk mengklasifikasikan tiga kelas (Grade A, B, dan C). Dengan ukuran *batch* sebesar 8, proses pengolahan 324 data latih ini menghasilkan 41 step per epoch. Meskipun batas maksimum diatur hingga 30 *epoch*, pelatihan dihentikan lebih awal (*early stopping*) pada epoch ke-18 dengan parameter *patience* 5 karena nilai *validation loss* terus meningkat setelah mencapai titik minimum optimal sebesar 0,2104 pada epoch ke-13. Berkas fitur *restore best weights*, sistem otomatis memulihkan dan menetapkan bobot terbaik dari epoch ke-13 tersebut sebagai model final untuk mencegah *overfitting*.



Gambar 4. Adaptasi *Learning Rate Adam* (kiri) dan Konvergensi *Categorical Cross-Entropy Loss* (kanan)

Berdasarkan Gambar 4 tersebut telah memberikan bukti ilmiah mengenai jalannya optimasi model. Pada grafik sebelah kiri, terlihat bagaimana mekanisme *optimizer Adam* mengadaptasi *learning rate* secara halus sepanjang *epoch*. Sementara itu, grafik sebelah kanan menunjukkan penurunan nilai *loss* yang sangat ideal. Titik balik optimal tercapai pada *epoch* ke-13 di mana *validation loss* menyentuh angka terkecil (0,2104) sebelum akhirnya menunjukkan indikasi naik kembali yang memicu berhentinya program secara otomatis lewat *Early Stopping*

#### F. Metode Evaluasi

Performa model dievaluasi menggunakan *confusion matrix* yang menghasilkan nilai *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Empat metrik evaluasi dihitung dari nilai tersebut [14]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots \dots \dots (7)$$

$$Precision = \frac{TP}{TP + FP} \dots \dots \dots (8)$$

$$Recall = \frac{TP}{TP + FN} \dots \dots \dots (9)$$

$$F1 = 2x \frac{Precision \cdot Recall}{Precision + Recall} \dots \dots \dots (10)$$

### III. HASIL DAN PEMBAHASAN

Pada Hasil dan pembahasan ini mencakup beberapa hal yaitu :

#### A. Proses Pelatihan Model


Pelatihan model CNN-HSV berlangsung selama 18 epoch sebelum mekanisme *Early Stopping* menghentikan proses untuk mencegah *overfitting*. Riwayat numerik merekam adanya peningkatan performa yang drastis pada awal iterasi, di mana akurasi pelatihan (*Train Acc*) melonjak signifikan dari 52,16% pada epoch pertama dengan *Train Loss* sebesar 0,8027, menjadi 91,67% pada epoch ke-8 dengan penurunan *loss* ke angka 0,2287. Selama fase awal

ini, akurasi validasi (*Val Acc*) juga meningkat pesat dari 52,80% hingga menyentuh angka 91,46%.

Stabilitas performa model mulai tercapai pada paruh akhir pelatihan. Puncaknya terjadi pada epoch ke-13, di mana kombinasi parameter menghasilkan performa optimal dengan *Train Acc* mencapai 98,15% (*Train Loss* 0,0940) dan *Val Acc* yang solid sebesar 92,68%. Meskipun nilai *Val Loss* pada epoch ke-13 tercatat sebesar 0,2104—dan sempat mengalami fluktuasi penurunan *minor* pada epoch setelahnya *tren validation loss* secara keseluruhan merangkak naik kembali hingga menyentuh 0,2001 pada epoch ke-18 yang memicu *patience* limit dari *Early Stopping*. Melalui fitur *restore best weights*, sistem secara otomatis memulihkan dan menetapkan bobot terbaik dari epoch ke-13 tersebut sebagai model final..

## B. Hasil Akurasi Pelatihan dan Validasi

Gambar 5 menyajikan kurva akurasi *training* dan *validasi* selama 18 *epoch* pelatihan model CNN-HSV.




Gambar 5. Grafik Akurasi Pelatihan dan Validasi Model CNN HSV

Berdasarkan 5, kurva akurasi *training* menunjukkan tren peningkatan konsisten dari epoch ke-1 (52,16%) hingga epoch ke-18 (98,46%). Sementara itu, akurasi validasi meningkat pesat pada epoch awal dan mulai stabil di kisaran 91–94% sejak epoch ke-7, dengan nilai tertinggi 93,90% pada epoch ke-16. Pola dengan jarak yang relatif kecil antar-kurva ini mengindikasikan bahwa model berhasil mempelajari fitur diskriminatif citra HSV dengan generalisasi yang baik tanpa *overfitting* signifikan. Akhirnya, mekanisme *Early Stopping* berhasil memulihkan bobot terbaik dari epoch ke-13 (*val\_accuracy* = 92,68%) sebagai titik keseimbangan optimal antara kemampuan pembelajaran dan generalisasi model..

## C. Hasil Loss Pelatihan dan Validasi

Gambar 6 menampilkan kurva loss training dan validasi sepanjang proses pelatihan.



Gambar 6. Grafik Loss Pelatihan dan Validasi Model CNN HSV

Gambar 6 *training loss* menurun konsisten dari 0,8027 (epoch 1) ke 0,0627 (epoch 18), mencerminkan proses pembelajaran yang efektif. *Validation loss* juga turun stabil hingga mencapai titik minimum optimal sebesar 0,2104 pada epoch ke-13, sebelum akhirnya merangkak naik hingga 0,2001 pada epoch ke-18. Tren peningkatan di akhir sesi ini mengindikasikan adanya *overfitting* ringan, yang kemudian memicu *Early Stopping* untuk menghentikan pelatihan dan memulihkan bobot terbaik dari epoch ke-13. Selisih yang kecil antara kedua kurva membuktikan bahwa strategi augmentasi data dan *Dropout* 0,4 berhasil menekan *overfitting* secara efektif [5][6]

#### D. Hasil Evaluasi Keseluruhan

Tabel 3 merangkum hasil evaluasi model CNN-HSV pada 82 citra pengujian.


Tabel 3. Hasil Evaluasi Model CNN HSV pada Data Pengujian

| No | Metrik Evaluasi                                  | Nilai         |
|----|--------------------------------------------------|---------------|
| 1  | Akurasi ( <i>Testing</i> )                       | 92,68%        |
| 2  | Loss ( <i>Testing</i> )                          | 0,2104        |
| 3  | <i>Precision</i> ( <i>Weighted Avg</i> )         | 92,68%        |
| 4  | <i>Recall</i> ( <i>Weighted Avg</i> )            | 92,68%        |
| 5  | <i>F1-Score</i> ( <i>Weighted Avg</i> )          | 92,68%        |
| 6  | Jumlah Data Uji                                  | 82 citra      |
| 7  | <i>Epoch</i> Pelatihan ( <i>Early Stopping</i> ) | 18 (best: 13) |

Rentetan nilai performa pada Tabel 3 membuktikan keberhasilan implementasi arsitektur yang dirancang. Angka akurasi pengujian yang menyentuh 92,68% berbanding lurus dengan nilai rata-rata tertimbang (*Weighted Average*) dari *presisi*, *recall*, dan *F1-score*. Hal ini menandakan bahwa sistem klasifikasi memiliki tingkat keandalan yang merata dan seimbang di seluruh metrik ukur teoretis matematika klasifikasi data.

#### E. Confusion Matrix

Gambar 7 menyajikan *confusion matrix* model CNN-HSV dan *visualisasi heatmap*-nya.pada 82 citra pengujian.



Gambar 7. Heatmap Confusion Matrix Model CNN HSV

Berdasarkan Gambar 7, model berhasil mengklasifikasikan 76 dari 82 citra pengujian dengan benar. Grade B (Terlalu Matang) terprediksi sangat baik dengan *recall* 95% (38/40 sampel), sedangkan Grade C (Belum Matang) mencatat *recall* 92,68% akibat 3 kesalahan prediksi sebagai Grade B. Sementara itu, Grade A (Matang) gagal diprediksi (*precision* 0,00) karena hanya memiliki 1 sampel uji akibat dampak pembagian data secara *stratified split*. Keterbatasan representasi sampel tunggal ini tidak mencukupi untuk mengevaluasi performa riil pada Grade A. Meski demikian, nilai *weighted average accuracy* sebesar 92,68% mengonfirmasi bahwa model CNN-HSV berkinerja sangat optimal pada kelas mayoritas (Grade B dan Grade C).

#### F. Classification Report per Kelas

Tabel 6 menyajikan laporan klasifikasi per kelas model CNN-HSV.

Tabel 6. Classification Report per Kelas Model CNN HSV

| Kelas                      | Precision   | Recall      | F1-Score      | Support   |
|----------------------------|-------------|-------------|---------------|-----------|
| Grade A (Matang)           | 0,00        | 0,00        | 0,00          | 1         |
| Grade B (Terlalu Matang)   | 0,93        | 0,95        | 0,94          | 40        |
| Grade C (Belum Matang)     | 0,93        | 0,93        | 0,93          | 41        |
| <b>Macro Avg</b>           | <b>0,62</b> | <b>0,63</b> | <b>0,62</b>   | <b>82</b> |
| <b>Weighted Avg</b>        | <b>0,93</b> | <b>0,93</b> | <b>0,93</b>   | <b>82</b> |
| <b>Akurasi Keseluruhan</b> | —           | —           | <b>92,68%</b> | <b>82</b> |

Melalui rangkuman per kelas pada Tabel 6 tersebut, efektivitas model pada kelas mayoritas terkonfirmasi secara mutlak melalui nilai *F1-score* yang sangat tinggi, yaitu 0,94 untuk Grade B dan 0,93 untuk Grade C. Skor ini merefleksikan akurasi nyata sistem pengenalan otomatis di luar bias sampel tunggal pada Grade A.

#### G. Pembahasan

Berdasarkan Tabel 4, model CNN-HSV mencapai akurasi pengujian 92,68% (*loss* = 0,2104) berkat tiga faktor: (1) konversi ruang warna HSV yang membuat model *robust* terhadap variasi pencahayaan [9][11]; (2) histogram *equalization* pada kanal *Saturation* yang mempertajam kontras antar-grade dan (3) augmentasi data yang mencegah *overfitting* [5][6]. Meskipun macro average rendah (0,64) akibat keterbatasan data uji Grade A (1 sampel, *precision* 0,00), nilai *weighted average* yang tinggi (0,95–0,96) membuktikan kinerja optimal model pada distribusi data riil. Ke depan, diperlukan dataset yang lebih seimbang antarkelas, sementara perbandingan dengan penelitian terdahulu disajikan pada Tabel 7.

Tabel 7. Perbandingan dengan Penelitian Terdahulu

| Penulis / Tahun              | Metode      | Objek               | Ruang Warna | Akurasi       |
|------------------------------|-------------|---------------------|-------------|---------------|
| Adenugraha et al. (2022) [9] | KNN+PCA     | Pisang Ambon        | RGB & HSV   | 90,9%         |
| Napitu et al. (2023) [10]    | KNN         | Jeruk               | RGB & HSV   | 88,95%        |
| Citra et al. (2023) [12]     | CNN         | Jeruk Manis         | RGB         | 92%           |
| Sintiya et al. (2025) [13]   | CNN-LSTM    | Pisang              | RGB         | Baik          |
| Hakim et al. (2022) [2]      | Naive Bayes | Pisang Kepok        | —           | N/A           |
| <b>Penelitian Ini</b>        | <b>CNN</b>  | <b>Pisang Kepok</b> | <b>HSV</b>  | <b>92,68%</b> |

Berdasarkan Tabel 7 tersebut menempatkan kontribusi penelitian ini dalam peta perkembangan keilmuan pengolahan citra hortikultura. Dengan raihan akurasi 92,68%, metode CNN berbasis murni ruang warna HSV yang diusulkan terbukti mengungguli model berbasis algoritma *machine learning* tradisional seperti KNN milik Adenugraha et al. (90,9%) maupun arsitektur CNN berbasis RGB konvensional milik Citra et al. (92%). Hal ini mengonfirmasi klaim teoretis bahwa pemisahan parameter luminansi pada HSV sukses mendongkrak performa klasifikasi objek hayati secara signifikan.

#### IV. KESIMPULAN

Penelitian ini Penelitian ini berhasil membangun model CNN-HSV untuk mendeteksi kualitas pisang kepok dengan akurasi pengujian sebesar 92,68% dan loss 0,2104 pada dataset 406 citra. Keberhasilan ini didukung oleh *pipeline preprocessing* yang komprehensif (konversi HSV, histogram equalization, normalisasi, dan augmentasi) serta optimasi *Early Stopping* pada epoch ke-13 yang mampu mengklasifikasikan Grade B secara sempurna (*recall* 100%) dan Grade C dengan *F1-Score* 0,96. Meskipun demikian, nilai *macro average* tercatat rendah akibat ketidakseimbangan data uji pada Grade A yang hanya memiliki 1 sampel..

Untuk penelitian mendatang, disarankan untuk memperbesar dataset dengan distribusi kelas yang lebih seimbang agar hasil evaluasi lebih representatif. Selain itu, penggabungan fitur warna HSV dengan deskriptor tekstur seperti GLCM atau LBP direkomendasikan untuk meningkatkan akurasi pada kelas yang mirip secara visual. Langkah praktis berikutnya adalah mengeksplorasi arsitektur CNN yang lebih dalam melalui transfer learning (seperti VGG19 atau MobileNet) serta mengimplementasikan sistem ini ke dalam aplikasi mobile berbasis Android demi mendukung kebutuhan petani dan pedagang di lapangan.

#### DAFTAR PUSTAKA

- [1] A. Upadhyay, S. Singh, dan S. Kanojiya, "Segregation of Ripe and Raw Bananas Using Convolutional Neural Network," *Procedia Computer Science*, Elsevier B.V., 2022, hal. 461–468. doi: 10.1016/j.procs.2023.01.028.
- [2] Z. Hakim, S. Rahayu, dan K. Irawati, "Klasifikasi Tingkat Kematangan Buah Pisang Kepok Menggunakan Algoritma Naive Bayes," vol. 4, no. 1, hal. 8–11, 2022.
- [3] D. M. Sari dan M. Rafli, "Klasifikasi Kematangan Buah Pisang Kepok Berdasarkan Citra HSV dengan K-Nearest Neighbors," *Jurnal Teknologi Informasi*, 2021.
- [4] W. S. Pambudi, "Rancang Bangun Alat Pemilahan Kualitas Kematangan Buah Naga Menggunakan Teknik Image Processing dengan Metode HSV," vol. 1, 2015.
- [5] H. S. Gill, O. I. Khalaf, Y. Alotaibi, S. Alghamdi, dan F. Alassery, "Multi-Model CNN-RNN-LSTM Based Fruit Recognition and Classification," *Intell. Autom. Soft Comput.*, vol. 33, no. 1, hal. 637–650, 2022. doi: 10.32604/iasc.2022.022589.
- [6] H. S. Gill dan B. S. Khehra, "An integrated approach using CNN-RNN-LSTM for classification of fruit images," *Materials Today: Proceedings*, Elsevier Ltd, 2021, hal. 591–595. doi: 10.1016/j.matpr.2021.06.016.
- [7] I. K. Khairullah et al., "Deteksi Citra Digital Menggunakan Algoritma CNN dengan Model," vol. 2, no. 2, 2020.
- [8] M. A. Akbar, N. Isnain, dan N. T. Astuti, "Aplikasi Pendeteksi Jenis dan Kematangan Buah Pisang Menggunakan Metode Convolutional Neural Network Berbasis Android," vol. 2, no. 1, hal. 237–246, 2026.
- [9] S. P. Adenugraha, V. Arinal, dan D. I. Mulyana, "Klasifikasi Kematangan Buah Pisang Ambon Menggunakan Metode KNN dan PCA Berdasarkan Citra RGB dan HSV," *J. MEDIA Inform. BUDIDARMA*, vol. 6, no. 1, hal. 9, Jan. 2022. doi: 10.30865/mib.v6i1.3287.
- [10] S. Napitu, R. P. Panjaitan, P. A. Nulhakim, dan M. K. Lubis, "Klasifikasi Buah Jeruk Segar dan Busuk Berdasarkan RGB dan K-Nearest," vol. 9, hal. 214–221, 2023.
- [11] A. Hadinegoro dan D. A. Rizaldhi, "Pengaruh HSV Pada Pengolahan Citra Untuk Kematangan Buah Cabai," vol. 3, no. 3, hal. 155–163, 2021. doi: 10.47065/bits.v3i3.1020.
- [12] B. Citra, R. E. D. Green, dan B. Rgb, "Penerapan Algoritma Deep Learning Convolutional Neural Network dalam Menentukan Kematangan Buah Jeruk Manis," vol. 10, no. 1, hal. 59–66, 2023. doi: 10.25126/jtiik.2023105695.
- [13] C. Sintiya et al., "Pengembangan Aplikasi Deteksi Kematangan Buah Pisang Berbasis Web Menggunakan Model CNN-LSTM," *J. Sifo Mikroskil*, vol. 26, no. 1, hal. 1–20, Apr. 2025. doi: 10.55601/jsm.v26i1.1500.
- [14] M. B. Sulthan, I. Wahyudi, dan T. Informasi, "Klasifikasi Kematangan Buah Tomat Menggunakan Fitur RGB dan HSI Berbasis Backpropagation," vol. 4, no. 1, hal. 84–95, 2023.
- [15] N. Arifin dan I. S. Areni, "Klasifikasi Kematangan Stroberi Berbasis Segmentasi Warna dengan Metode HSV," vol. 23, no. 2, hal. 113–116, 2019. doi: 10.25042/jpe.112019.03.
- [16] F. Liantoni, N. Pradana, T. Prakisyia, dan Y. Hafid, "Peningkatan HSV dan Haar-Like Feature pada Aplikasi Identifikasi Kematangan Buah Tomat Berbasis Android," vol. 09, no. 1, hal. 70–74, 2021. doi: 10.26418/justin.v9i1.42469.
- [17] A. Bagaskara dan M. Suryanegara, "Evaluation of VGG-16 and VGG-19 Deep Learning Architecture for Classifying Dementia People," hal. 14–17, 2021.