

# Implementasi Computer Vision Terhadap Jenis Kualitas Pisang Susu Menggunakan Metode YOLOv8n Berbasis WebApps

Inna Fatahna<sup>1</sup>, Putri Desi Kusuma Sari<sup>2</sup>, Annisa' Nur Kamilah<sup>3</sup>, Resty Wulanningrum<sup>4</sup>, Wahyu Cahyo Utomo<sup>5</sup>

<sup>1-5</sup>Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: <sup>1</sup>[innafatahna14@gmail.com](mailto:innafatahna14@gmail.com), <sup>2</sup>[putridesi825@gmail.com](mailto:putridesi825@gmail.com), <sup>3</sup>[nurkamilahannisa8@gmail.com](mailto:nurkamilahannisa8@gmail.com),

<sup>4</sup>[restyw@unpkdr.ac.id](mailto:restyw@unpkdr.ac.id), <sup>5</sup>[wahyu.utomo@unpkdr.ac.id](mailto:wahyu.utomo@unpkdr.ac.id)

**Abstrak –** Penelitian ini mengeksplorasi penerapan teknologi computer vision untuk mendeteksi kualitas pisang khususnya jenis pisang susu, komoditas ekspor potensial di Kediri yang menghadapi tantangan dalam perawatan dan pengendalian kualitas. Metode YOLOv8n dan CNN (Convolutional Neural Network) digunakan untuk mengatasi masalah rendahnya kualitas hasil panen akibat metode tradisional dalam menentukan kematangan buah. Kematangan yang tidak tepat dapat mempengaruhi rasa, aroma, dan umur simpan pisang. CNN menganalisis warna dan tekstur buah, sementara YOLOv8n memungkinkan deteksi objek secara real-time dengan akurasi tinggi. Model dilatih selama 100 epoch dengan ukuran batch 8, dataset terdiri dari 200 gambar (70% pelatihan, 20% validasi, 10% pengujian), dengan menghasilkan rata-rata presisi 89,75% dan akurasi mAP50 92%. Implementasi dalam framework Streamlit menyediakan antarmuka WebApps yang user-friendly, memungkinkan pengguna mengunggah gambar dari komputer lokal, tautan, atau video kamera real-time. Hasil penelitian meningkatkan efisiensi dalam menentukan kematangan pisang susu dan memberikan solusi objektif, berpotensi meningkatkan daya saing pasar serta manfaat bagi petani dalam menentukan waktu panen optimal.

**Kata Kunci** — CNN, Computer Vision, Pengolahan Citra, Pisang Susu, YOLOv8n

## 1. PENDAHULUAN

Tanaman pisang merupakan tanaman hortikultura yang menjadi salah satu bahan ekspor unggulan yang mempunyai potensi besar bagi negara[1]. Di Kediri pisang yang ditanam di pekarangan seringkali tidak mendapatkan perawatan intensif, sehingga produksinya rendah dan kalah bersaing di pasar internasional[2]. Pisang susu adalah salah satu jenis pisang yang memiliki nilai tambah tinggi karena kualitas buahnya yang manis dan kaya akan kandungan nutrisinya[3]. Kematangan buah pisang mempengaruhi kualitasnya dan menjadi pertimbangan sebelum dipanen. Buah yang dipetik terlalu muda, meskipun sudah matang, biasanya tidak memiliki rasa dan aroma yang optimal. Sebaliknya, buah yang terlalu tua akan terasa lebih manis dan aromatik, namun umur simpannya lebih pendek. Oleh karena itu, kematangan panen harus disesuaikan jangkauan pemasaran dan kegunaan buah pisang susu[4].

Pisang susu di wilayah Kediri menghadapi tantangan dalam menjaga kualitas dan nilai ekonomi hasil panen. Banyak petani yang masih menggunakan metode tradisional untuk menentukan kematangan buah, yang memiliki resiko menghasilkan buah terlalu matang atau muda. Tingkat kematangan saat panen sangat mempengaruhi umur simpan dan kualitas buah[5]. Selain itu, tingkat kematangan buah saat panen juga berpengaruh terhadap grade pisang yang akan dipasarkan di mall, sehingga pemilihan tingkat kematangan yang tepat dapat meningkatkan daya saing produk di pasar modern. Untuk mengatasi masalah yang dapat membantu mengenali tingkat kematangan buah pisang secara akurat dapat menggunakan metode YOLOv8n dan CNN[6].

Penggunaan YOLOv8n dan Convolutional Neural Network (CNN) untuk mendeteksi kematangan pisang susu merupakan pendekatan yang efektif dan inovatif. CNN dapat mendeteksi tingkat kematangan berdasarkan warna dan tekstur, sehingga membantu petani menentukan waktu terbaik untuk panen. Sementara itu YOLOv8n memungkinkan deteksi objek secara real-time dengan akurasi tinggi, sehingga memudahkan identifikasi kematangan buah di lapangan. Kombinasi kedua teknologi ini meningkatkan efisiensi dan kualitas hasil panen serta memberikan solusi yang lebih objektif dibandingkan metode tradisional. Pengenalan teknologi ini diharapkan dapat meningkatkan daya saing dan kualitas produk pisang susu dipasaran[7],[8].

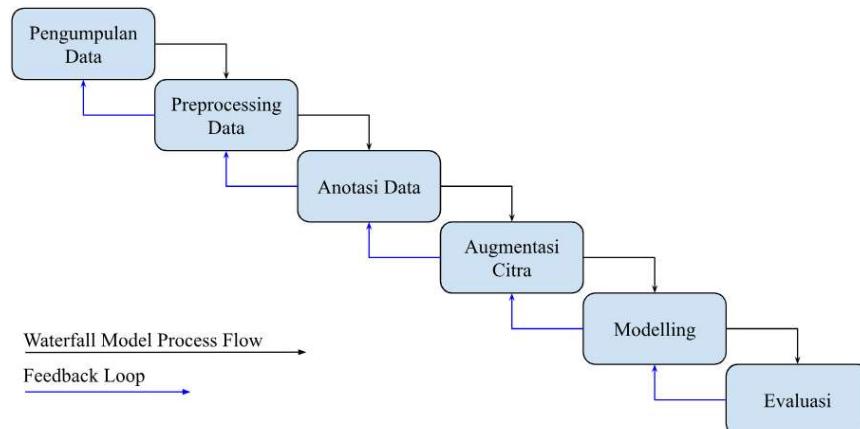
Penelitian sebelumnya, klasifikasi kematangan buah pisang menggunakan metode Convolutional Neural Network (CNN) dan YOLOv8n telah menunjukkan hasil yang menjanjikan dengan mengimplementasikan CNN untuk mengklasifikasi tingkat kematangan pisang dengan akurasi 95% dan menerapkan YOLOv8n untuk mencatat nilai mAP sebesar 81%, menunjukkan kemampuan deteksi yang baik dalam waktu yang baik dalam mendeteksi objek real-time[9]. Kedua pendekatan tersebut bertujuan untuk meningkatkan efisiensi pemilahan pasca panen, yang sangat penting bagi petani untuk memastikan kualitas produk yang optimal[10].

Solusi dalam permasalahan tersebut dapat menggunakan berbasis web untuk membantu petani menentukan kematangan pisang susu. Dengan menggunakan YOLOv8n dan CNN yang dirancang untuk memudahkan dalam mendeteksi kematangan buah dan mengukur tingkat akurasi. Pada aplikasi ini menyediakan fitur utama berupa deteksi otomatis kematangan melalui *upload* gambar atau menggunakan kamera langsung, sehingga dapat segera mengetahui kondisi buah di lapangan. Sistem deteksi menggunakan YOLOv8n untuk mengidentifikasi objek *real-time* dan CNN sebagai analisis tingkat kematangan berdasarkan warna dan tekstur buah. Dengan solusi ini, petani dapat meningkatkan efisiensi pemanenan, mengurangi resiko panen buah yang terlalu matang atau terlalu muda, serta memastikan bahwa *grade* pisang susu yang dihasilkan sesuai dengan standar kualitas *mall*.

Standar kualitas *mall* pada aplikasi deteksi kematangan pisang susu dengan menggunakan YOLOv8n dan CNN bertujuan untuk memastikan buah pisang yang dipanen memenuhi tingkat kualitas yang tinggi. Aplikasi ini membantu petani secara otomatis menentukan waktu panen yang optimal dengan menganalisis warna dan tekstur buah secara *real-time* mengurangi risiko tepat panen dan meningkatkan daya saing produk pisang susu di pasar.

## 2. METODE PENELITIAN

Pada penelitian ini digunakan pendekatan komprehensif untuk mengetahui tingkat kematangan pisang susu. Proses yang terlibat mencakup beberapa fase utama, mulai dari pengumpulan data, pengelolaan data dan augmentasi gambar hingga implementasi model. Alur penelitian ini telah dicantumkan pada Gambar 1 berikut:



Gambar 1. Diagram *Waterfall Model*

## 2.1 Pengumpulan Data

Dalam penelitian ini, data dikumpulkan melalui roboflow, dengan total 130 gambar untuk kategori *fresh* dan 70 gambar untuk kategori *rotten*.

## 2.2 Preprocessing Data

Sebelum dianalisis lebih lanjut, citra yang dikumpulkan menjalani proses pra pemrosesan yang meliputi: pada normalisasi dilakukan penskalaan kembali terhadap nilai – nilai yang tersimpan pada dataset yang membuat proses pengolahan menjadi lebih mudah[11], dan *Resize* yaitu mengubah ukuran citra dalam satuan pixel[12].

## 2.3 Anotasi Data

Pada tahap anotasi, dilakukan segmentasi objek menggunakan citra digital pisang untuk memisahkan objek utama dari latar belakang [13]. Langkah ini mempermudah model dalam mengenali ciri-ciri penting dari objek. Hasil segmentasi berupa citra hitam-putih, di mana objek utama dipisahkan secara jelas dari latar belakang.

Proses segmentasi ini dilakukan melalui Roboflow, sebuah platform berbasis web yang mendukung pengumpulan, anotasi, dan pra-pemrosesan dataset. Melalui Roboflow, pengguna dapat melakukan anotasi dan segmentasi objek dengan lebih efisien, termasuk manipulasi seperti perluasan gambar (*image augmentation*) yang berguna dalam proses pelatihan model [14].

## 2.4 Augmentasi Citra

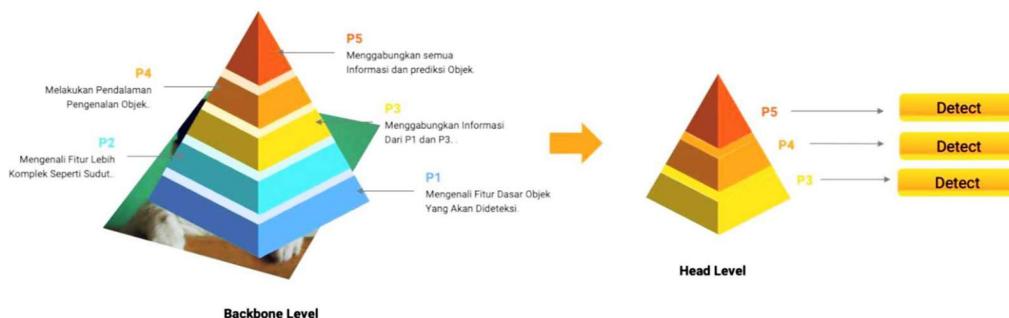
Karena jumlah data yang dikumpulkan dalam penelitian ini masih tergolong sedikit, maka dilakukan proses pengayaan data untuk menambah jumlah variasi data yang ada. Augmentasi data adalah teknik yang digunakan untuk membuat variasi data baru dari data yang sudah ada dengan melakukan transformasi pada gambar. Hal ini meningkatkan keragaman data yang digunakan dan membantu mencegah *overfitting*. Proses augmentasi data dilakukan menggunakan perpustakaan *ImageDataGenerator*, yang merupakan bagian dari kerangka Keras[15].

Teknik augmentasi yang digunakan dalam penelitian ini adalah: teknik *flip left-right*, *flip top-bottom*. Akibat perluasan ini, kumpulan data berfluktuasi, sehingga membantu model mendeteksi berbagai kondisi pematangan pisang. Augmentasi ini menghasilkan total 200 gambar, 130 kategori *fresh*, 70 kategori *rotten*.

## 2.5 Modelling

Dalam penelitian ini, digunakan teknologi *Computer Vision*, yang merupakan bidang kecerdasan buatan yang memungkinkan komputer untuk memahami dan menafsirkan informasi visual dari gambar atau video[16]. Salah satu metode yang banyak digunakan dalam *Computer Vision* adalah *Convolutional Neural Network* (CNN). CNN adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra[17].

Metode CNN yang diterapkan dalam penelitian ini menggunakan algoritma YOLOv8n. YOLOv8 (*You Only Look Once* versi 8) adalah model deteksi objek yang memiliki keunggulan dalam hal akurasi dan kecepatan dibandingkan versi YOLO sebelumnya. YOLOv8 dirancang untuk melakukan deteksi objek secara *real-time*, sehingga ideal untuk tugas deteksi dan klasifikasi kesegaran buah dengan presisi tinggi.



Gambar 2. Arsitektur YOLOv8

(Sumber Gambar : <https://jurnal.polsri.ac.id/index.php/jupiter/article/view/8633/3151>)

Pada Gambar 2 dapat dilihat bahwa YOLOv8 memiliki dua komponen utama dalam arsiteturnya : *backbone* dan *head*. *Backbone* adalah bagian dari *Convolutional Neural Network* (CNN) yang berfungsi untuk mengekstrak fitur dari data masukan, seperti gambar dan video[18]. *Backbone* ini terdiri dari lima level, yang masing-masing mewakili tahap dalam proses deteksi objek:

1. Tahap P1 digunakan untuk mendeteksi ciri-ciri dasar objek seperti garis, bentuk, warna, dan elemen visual dasar lainnya.
2. P2 untuk mendeteksi fitur objek yang lebih kompleks, seperti sudut gambar.
3. P3 digunakan menggabungkan dan memproses lebih lanjut informasi yang dikumpulkan oleh P1 dan P2.
4. Lapisan P4 digunakan untuk meningkatkan deteksi objek yang dikumpulkan di lapisan P1 dan P2.
5. Lapisan P5 digunakan untuk menggabungkan semua informasi dan prediksi objek sekaligus berfungsi sebagai dasar untuk proses deteksi objek pada tahapan berikutnya.

Lapisan-lapisan ini bekerja bersama untuk mendukung proses deteksi objek pada YOLOv8, sehingga menghasilkan model yang efisien dalam mengklasifikasikan dan mengenali objek secara tepat di berbagai kondisi visual. Selain itu, untuk lapisan *head*, membuat *Bounding Box* gunakan rumus (1).

$$(x, y) = \left( \frac{1}{1+e^{-tx}}, \frac{1}{1+e^{-ty}} \right) \dots\dots\dots(1)$$

- a.  $(x,y)$  merupakan koordinat pusat dari *bounding box* objek. Sedangkan  $(tx,ty)$  merupakan koordinat pusat dari *bounding box* objek yang dihitung menggunakan fungsi sigmoid sebagaimana yang dijelaskan dalam rumus (1). Kemudian, untuk menentukan ukuran *bounding box*, akan digunakan rumus (2).

$$(w, h) = (pw \cdot e^{tw}, ph \cdot e^{th}) \dots\dots\dots(2)$$

- b. dimana  $pw$  dan  $ph$  merepresentasikan dimensi *anchor box* yang dipilih, sedangkan  $tw$  dan  $th$  adalah output dari jaringan saraf untuk dimensi kotak pembatas objek. Lalu untuk menghitung *confidence score* maka akan menggunakan rumus (3).

$$P(\text{Objek}) = \sigma(t_{obj}) \dots\dots\dots(3)$$

c. Dimana  $t_{obj}$  adalah *output* jaringan saraf yang menunjukkan probabilitas keberadaan objek.

Model YOLOv8n diterapkan untuk mendeteksi kematangan pisang susu dan mengklasifikasikannya menjadi dua kategori: *Fresh* dan *Rotten*. Model ini dilatih menggunakan augmented data dimana datanya dibagi sebagai berikut. 70% untuk data latih , 20% untuk data validasi , dan 10% untuk data uji.

## 2.6 Matriks Evaluasi Model

Untuk menentukan tingkat keberhasilan dari kinerja sistem menggunakan model yang telah dilatih untuk mendeteksi objek digunakan matriks evaluasi diantaranya adalah *Accuracy*, *Precision*, *Recall*, *F1-Score*, mAP, *Confusion Matrix*. *Confusion matrix* adalah tabel yang menyatakan klasifikasi jumlah data uji yang benar dan jumlah data uji yang salah. Contoh confusion matrix untuk klasifikasi biner ditunjukkan pada Tabel 1[19].

Tabel 1. *Confusion Matrix*

| Class   | Kelas Positif       | Kelas Negatif       |
|---------|---------------------|---------------------|
| Positif | TP (True Positive)  | TN (True Negative)  |
| Negatif | FP (False Positive) | FN (False Negative) |

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

$$\text{Precision} = \frac{TP}{(TP+F)}$$

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

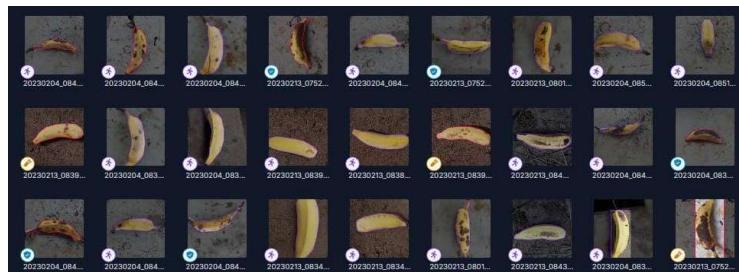
$$\text{F-1 Score} = 2 * \frac{(\text{Recall} * \text{Precision})}{(\text{Recall} + \text{Precision})}$$

$$\text{mAP} = \sum_{i=1}^N \frac{AP(i)}{N} * 100\%$$

## 3. HASIL DAN PEMBAHASAN

### 3.1 Pengumpulan Data

Pengumpulan data adalah langkah awal penting dalam penelitian atau pengembangan, di mana data dikumpulkan untuk dianalisis lebih lanjut. Dalam pengembangan model kecerdasan buatan (AI), proses ini mencakup tidak hanya pengumpulan data mentah, tetapi juga persiapan dan pemrosesan agar data siap digunakan secara efektif. Salah satu *platform* yang mempermudah proses ini adalah Roboflow, sebuah *platform web* yang dirancang untuk mengelola dan mempersiapkan dataset, terutama dalam konteks pelatihan model AI. Proses pengumpulan data menghasilkan total 200 gambar, 130 kategori *fresh* atau segar, 70 kategori *rotten* atau busuk. Berikut ini hasil proses pengumpulan data yang dapat dilihat pada Gambar 3.



Gambar 3. Hasil Proses Pengumpulan Data

Hasil proses pengumpulan data menggunakan Roboflow yang menyediakan berbagai fitur seperti perluasan gambar dan anotasi, yang memungkinkan pengguna untuk melakukan teknik pra-pemrosesan data dengan mudah terdapat pada Gambar 3. Dengan menggunakan Roboflow, pengguna dapat menyiapkan data dengan lebih efisien sebelum digunakan dalam pelatihan model, memastikan bahwa dataset yang digunakan sudah dalam bentuk optimal untuk mencapai hasil yang lebih baik.

### 3.2 Preprocessing Data

Sebelum dianalisis lebih lanjut, citra yang dikumpulkan menjalani proses prapemrosesan yang meliputi:

- Normalisasi: Mengubah ukuran gambar untuk konsistensi.
- Peningkatan Kontras: Meningkatkan visibilitas fitur penting dalam gambar.

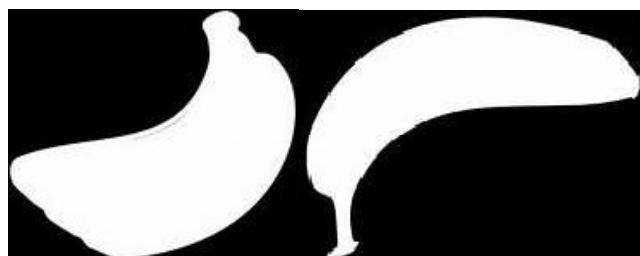


Gambar 4. Resize dan Normalisasi

Karena jumlah data yang dikumpulkan dalam penelitian ini masih tergolong sedikit, maka dilakukan proses pengayaan data untuk menambah jumlah variasi data yang ada seperti pada Gambar 4. Jika model membutuhkan input berukuran 224x224 piksel, maka semua gambar akan diubah ukurannya menjadi 224x224 piksel, meskipun ukuran asli gambar tersebut berbeda. *Resize* memastikan bahwa gambar-gambar yang digunakan dalam pelatihan memiliki ukuran yang sama, yang penting untuk menjaga kestabilan dan keefektifan pelatihan. Normalisasi menyesuaikan nilai piksel gambar, biasanya dengan mengubah rentang nilai dari 0-255 menjadi 0-1 atau -1 hingga 1, untuk memudahkan model dalam memproses data dan mempercepat konvergensi selama pelatihan. Augmentasi data adalah teknik yang digunakan untuk membuat variasi data baru dari data yang sudah ada dengan melakukan transformasi pada gambar. Hal ini meningkatkan keragaman data yang digunakan dan membantu mencegah *overfitting*. Proses augmentasi data dilakukan menggunakan `ImageDataGenerator`, yang merupakan bagian dari perpustakaan kerangka Keras.

### 3.3 Anotasi Data

Anotasi data dan segmentasi gambar merupakan langkah penting dalam mempersiapkan dataset untuk pelatihan model kecerdasan buatan. Pada tahap segmentasi, citra digital dipisahkan menjadi dua bagian utama, yaitu objek dan latar belakang, agar model dapat mudah mengenali ciri-ciri penting dari objek yang dianalisis.

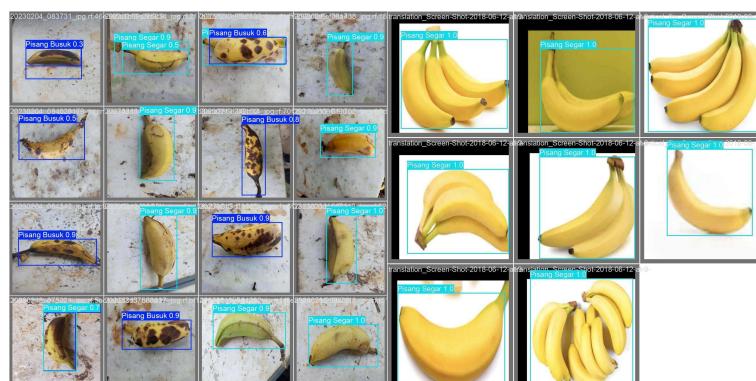


Gambar 5. Segmentasi Gambar Pisang Susu

Teknik segmentasi pada Gambar 5 yang dihasilkan dalam penelitian ini meliputi *thresholding*, yang memanfaatkan ambang batas intensitas untuk memisahkan objek dari latar belakang berdasarkan perbedaan nilai piksel, dan *contour detection*, yang berfungsi untuk mengidentifikasi bentuk objek dengan mendeteksi garis batas atau kontur yang memisahkan objek dari area sekitarnya. Kedua teknik ini diimplementasikan untuk meningkatkan akurasi model dalam mengenali dan mengklasifikasikan objek secara lebih efektif.

### 3.4 Augmentasi Citra

Augmentasi citra dilakukan untuk menambah jumlah data pelatihan. Teknik augmentasi yang digunakan dalam penelitian ini adalah: teknik *flip left-right* dan *flip top-bottom*. Akibat perluasan ini, kumpulan data berfluktuasi, sehingga membantu model mendeteksi berbagai kondisi pematangan pisang.



Gambar 6. Hasil Citra Deteksi

Ditampilkan hasil deteksi pada Gambar 6 yang menunjukkan *confidence score* antara *range* bervariasi dari 0.2 hingga 1.0 dalam mengidentifikasi kesegaran buah. Angka-angka ini mengindikasikan bahwa model yang digunakan memiliki kemampuan yang baik dalam mendeteksi tingkat kesegaran buah pisang susu. Hal ini penting karena akurasi dalam mendeteksi kesegaran tidak hanya berkontribusi pada kualitas produk, tetapi juga dapat mempengaruhi kepuasan konsumen hingga *grade* jenis buah pisang susu yang akan dipasarkan di *mall*. Dengan perkembangan teknologi dan algoritma terbaru, model ini semakin efisien dan dapat diandalkan untuk memberikan penilaian yang akurat terhadap kondisi buah pisang susu yang dideteksi.

### 3.5 Modelling

Pelatihan model menggunakan YOLOv8n yang dilatih sebelumnya dilakukan dengan memanfaatkan dataset disimpan di Google Drive seperti pada Gambar 7 berikut dibawah ini.

```

Banana Predict Modelling YOLO v8.ipynb ☆
File Edit View Insert Runtime Tools Help Last saved at 3:20PM

+ Code + Text
[?] [x] [?] [?]
Epoch 0/5/100 GPU mem box loss cls loss df1 loss Instances Size
0/5/100 900 0.4700 0.2460 0.2452 11 4158: 300K 9/9 [00:01:00~00, 5.35it/s]
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 6.88it/s]
all 40 0.853 0.929 0.922 0.053
Epoch 0/5/100 GPU mem box loss cls loss df1 loss Instances Size
0/5/100 900 0.4700 0.2460 0.2452 11 4158: 300K 9/9 [00:01:00~00, 5.35it/s]
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 7.06it/s]
all 40 0.851 0.921 0.926 0.053
Epoch 0/5/100 GPU mem box loss cls loss df1 loss Instances Size
0/5/100 900 0.4700 0.2460 0.2452 11 4158: 300K 9/9 [00:01:00~00, 5.35it/s]
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 6.14it/s]
all 40 0.850 0.920 0.924 0.056
Epoch 0/5/100 GPU mem box loss cls loss df1 loss Instances Size
0/5/100 900 0.4550 0.2460 0.2452 11 4158: 300K 9/9 [00:01:00~00, 5.56it/s]
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 6.34it/s]
all 40 0.925 0.868 0.919 0.062
Epoch 0/5/100 GPU mem box loss cls loss df1 loss Instances Size
0/5/100 900 0.4480 0.2460 0.2452 11 4158: 300K 9/9 [00:01:00~00, 5.25it/s]
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 3.11it/s]
all 40 0.926 0.866 0.919 0.066
Epoch 0/5/100 GPU mem box loss cls loss df1 loss Instances Size
0/5/100 900 0.4480 0.2460 0.2452 11 4158: 300K 9/9 [00:01:00~00, 5.25it/s]
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 2.99it/s]
all 40 0.926 0.867 0.919 0.069
Speed: 0.0m preprocess, 2.0ms inference, 1.0ms link, 2.4ms postprocess per image
100 epochs completed in 0.005 hours.
Optimizer: AdamW, lr=0.0001, weight_decay=0.05, eps=1e-08
Optimizer stripped from runs/detect/train/weights/best.pt...
Validating runs/detect/train/weights/best.pt...
Ultraalytics 0.3.10+ Python-3.10.12 torch-2.1.1+cu221 CUDA10 (Tesla T4, 15180MB)
Model summary (Total): 166 layers, 2,696,768 parameters, 6,330 gradients, 6,330 backward steps
Class Images Instances BoxIP R mAP50 mAP50-95: 300K 2/2 [00:00:00~00, 2.99it/s]
Pisang Busuk 30 32 0.853 0.844 0.867 0.428
Pisang Segar 30 32 0.853 0.844 0.867 0.428
Speed: 0.0m preprocess, 2.0ms inference, 1.0ms link, 2.4ms postprocess per image

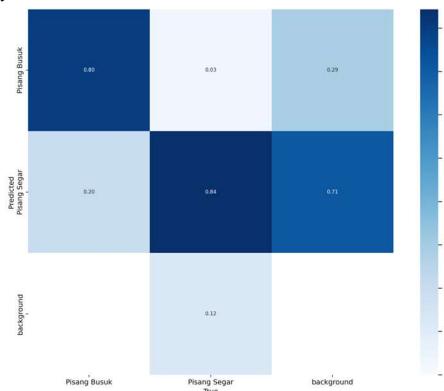
```

Gambar 7. Proses Modelling YOLOv8n

Pada Gambar 7 dataset ini terdiri dari 200 *image* yang telah dibagi menjadi tiga bagian: 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Selama proses pelatihan pada Gambar 6, model berusaha untuk memperbarui bobotnya guna meningkatkan akurasi dalam memprediksi *bounding box* pada objek. Proses ini berlangsung selama 2 jam dan 5 menit, dengan total 100 *epoch*. Hasil dari pelatihan menunjukkan performa yang sangat baik, dengan tingkat *precision* mencapai 92,6%, *recall* 86,9%, mAP50 92%, dan mAP50-95 66,1%.

### 3.6 Matriks Evaluasi Model

#### 3.6.1 Confusion Matrix Normalized



Gambar 8. Confusion Matrix Normalized

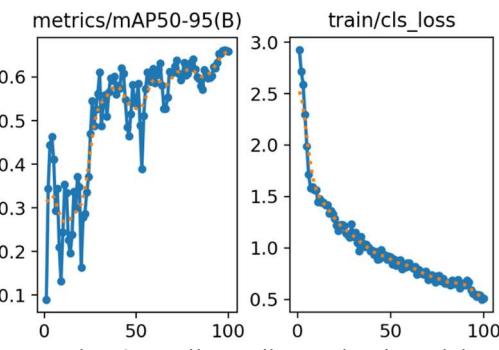
Pada Gambar 8, peneliti akan mengevaluasi kinerja model YOLOv8n yang telah dikembangkan melalui serangkaian pengujian. Pada tahap awal, peneliti menerapkan *Confusion Matrix Normalized* untuk menilai kemampuan model dalam membedakan jenis kualitas buah segar dan buah yang telah mengalami pembusukan. Nilai persentase dalam *confusion matrix* yang dinormalisasi memberikan gambaran yang jelas tentang seberapa baik model dalam mengklasifikasikan objek dengan benar. Nilai-nilai dalam *confusion matrix*, seperti *Precision*, *Recall*, dan *F1-score*, dapat dihitung untuk menilai akurasi model dalam membedakan buah segar dan busuk. Hasil evaluasi model ini menunjukkan kinerja yang solid, dengan akurasi 92%, dan *precision* serta *recall* yang cukup tinggi untuk kedua kategori, meskipun ada area yang dapat ditingkatkan, seperti kesalahan minor kelas.

Tabel 2. *Performance Modelling* Pisang Susu

| Class        | Images | Instances | Box Precision | Box Recall | mAP50 | mAP50-95 |
|--------------|--------|-----------|---------------|------------|-------|----------|
| All          | 200    | 42        | 0.926         | 0.869      | 0.92  | 0.661    |
| Pisang Busuk | 70     | 10        | 1             | 0.893      | 0.972 | 0.694    |
| Pisang Segar | 130    | 32        | 0.853         | 0.844      | 0.867 | 0.628    |

Berdasarkan hasil yang ditampilkan dalam grafik pada Tabel 2 terlihat bahwa model YOLOv8n mencapai tingkat akurasi yang sangat baik dalam mendekripsi kesegaran buah pisang susu, dengan nilai rata-rata akurasi berkisar antara 0.867 hingga 0.972 untuk setiap *class* kualitas buah yang diuji. Angka ini menunjukkan kemampuan model untuk secara efektif membedakan antara buah segar dan busuk dalam berbagai kondisi serta variasi yang ada. Hal ini diperkuat oleh rincian yang ada memberikan gambaran lebih mendalam mengenai performa model dalam kondisi kategori yang ditentukan. Dengan akurasi yang konsisten ini, model YOLOv8n dapat diandalkan untuk aplikasi praktis dalam industri pertanian dan distribusi pangan.

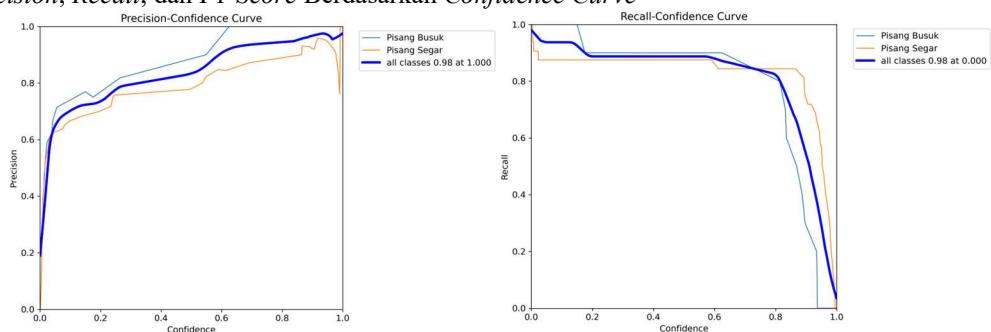
### 3.6.2 Hasil Matriks Evaluasi Model



Gambar 9. Hasil Matriks Evaluasi Model

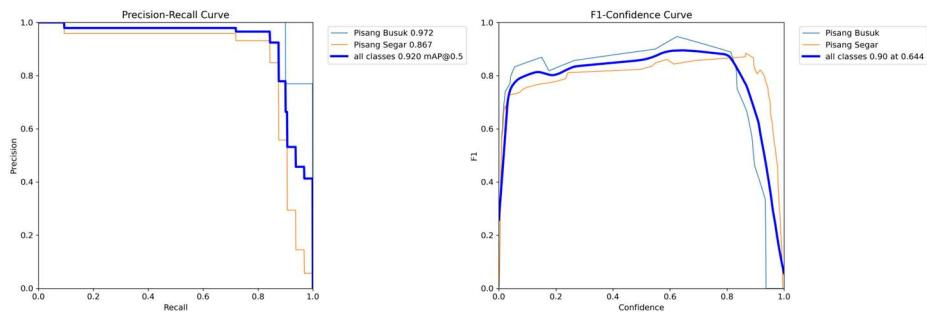
Pada Gambar 9. Hasil Matriks Evaluasi Model menunjukkan hasil evaluasi dari beberapa metrik penting dalam deteksi objek dan pelatihan model. mAP50-95(B), yang mengukur rata-rata presisi pada berbagai level ketelitian. Sementara itu, nilai *train/box\_loss* sebesar 0.03, *train/cls\_loss* sebesar 0.05, dan *train/dfl\_loss* sebesar 0.02 menunjukkan bahwa model berhasil meminimalkan kesalahan dalam prediksi *bounding box*, klasifikasi objek, dan distilasi fitur. Penurunan tren loss sepanjang pelatihan menunjukkan bahwa model semakin baik dalam memprediksi objek dan klasifikasinya seiring berjalannya waktu. Secara keseluruhan, hasil ini menunjukkan kinerja model yang solid, meskipun masih ada potensi untuk peningkatan lebih lanjut.

### 3.6.3 Precision, Recall, dan F1-Score Berdasarkan Confidence Curve



Gambar 10. *Precision* dan *Recall* Berdasarkan *Confidence Curve*

Dalam evaluasi pertama, model YOLOv8n yang telah dilatih menunjukkan *precision* mencapai 98% pada tingkat kepercayaan 100% sesuai pada Gambar 10. Ini menandakan bahwa pada tingkat kepercayaan yang sangat tinggi, model ini mampu mengidentifikasi dan mengklasifikasikan objek dari semua kelas dengan akurasi yang optimal. Sebaliknya, pada tingkat kepercayaan terendah, yaitu 0%, model YOLOv8n tetap menunjukkan performa yang baik dengan *recall* atau sensitivitas deteksi sebesar 98%. Hal ini menunjukkan bahwa meskipun model memiliki keyakinan yang rendah terhadap prediksinya, ia tetap mampu mengenali dan mengidentifikasi objek di semua kelas dengan tingkat akurasi yang memuaskan. Temuan ini menyoroti kemampuan model untuk tetap efektif dalam kondisi yang kurang ideal, menunjukkan potensi aplikatifnya berbagai situasi di dunia nyata.

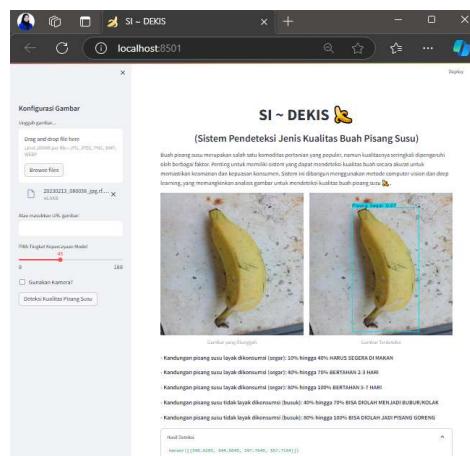


Gambar 11. F1-Score Berdasarkan *Confidence Curve*

Grafik yang ditampilkan dalam Gambar 11 menunjukkan hasil evaluasi F1-Score model, di mana presisi dicapai adalah sebesar 0.92 atau 92% dengan ambang batas *threshold* di atas 50%. Hasil ini mengindikasikan bahwa model memiliki keseimbangan yang cukup baik antara *precision* dan *recall* ketika tingkat kepercayaan melebihi 50%. Keseimbangan ini penting karena memastikan bahwa model tidak hanya mampu mendeteksi objek dengan tepat, tetapi juga meminimalkan kesalahan dalam klasifikasi. Dengan F1-Score yang menggambarkan performa keseluruhan, hasil ini menegaskan bahwa model dapat diandalkan dalam melakukan identifikasi objek secara efektif dalam konteks yang diuji.

### 3.7 Implementasi *Framework Streamlit*

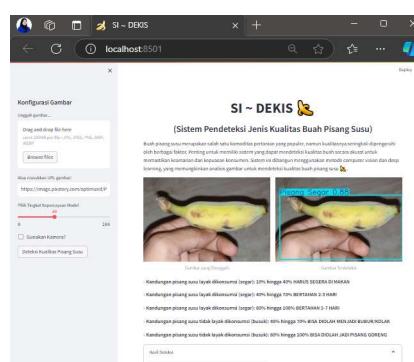
#### 3.7.1 WebApps Upload Gambar Dari Komputer Lokal



Gambar 12. Tampilan WebApps Upload Gambar Dari Komputer Lokal

Pada Gambar 12 dijelaskan bahwa pengguna meng-*upload* gambar buah pisang susu dari komputer lokal untuk analisis kualitas. Setelah memilih file, model YOLOv8n memproses gambar dan menampilkan hasil, menunjukkan apakah pisang susu segar atau busuk. Fitur ini menawarkan kemudahan deteksi pada gambar statis dengan antarmuka yang *user-friendly*.

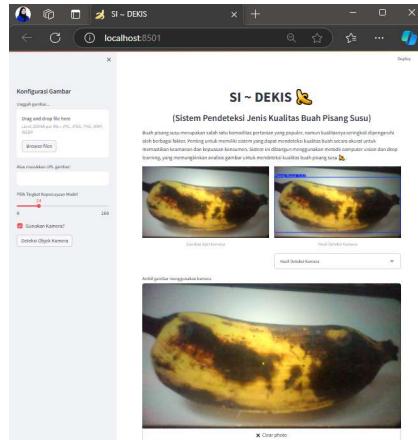
#### 3.7.2 WebApps Melalui Tautan (url) Gambar Pisang



Gambar 13. Tampilan WebApps Melalui Tautan (url) Gambar Pisang

Pada Gambar 13 dijelaskan bahwa akses gambar pisang melalui tautan (URL) untuk analisis kualitas perlu memasukkan URL gambar, dan model YOLOv8n memproses secara otomatis. Hasil analisis ditampilkan, menunjukkan pisang segar atau busuk, dengan antarmuka intuitif untuk pengalaman pengguna cepat dan efisien.

### 3.7.3 WebApps Real-Time Dari Video Kamera



Gambar 14. Tampilan WebApps Real-Time Dari Video Kamera

Pada Gambar 14 dijelaskan bahwa model deteksi kualitas buah pisang susu telah diterapkan di sebuah situs web untuk analisis *real-time* menggunakan webcam dan video. Keterbatasan dataset membuat model ini hanya dapat mendeteksi pisang susu segar dan busuk tertentu. Gambar di atas menunjukkan hasil pengujian model YOLOv8n dengan video ber-*frame rate* rendah akibat keterbatasan perangkat, meskipun menunjukkan potensi dalam pemantauan kualitas buah secara *real-time*. Pengujian model YOLOv8n diintegrasikan ke dalam model yang menunjukkan performa cukup baik dalam situasi deteksi waktu nyata.

## 4. SIMPULAN

Dengan mempertimbangkan hasil evaluasi yang dilakukan, beberapa hal dapat disimpulkan sebagai berikut:

1. Pisang susu memiliki nilai tambah tinggi dengan kualitas buah yang kaya nutrisi. Tingkat kematangan buah pisang susu sangat mempengaruhi rasa, kualitas, aroma dan umur simpannya. Dengan mempertimbangkan dampak pada grade yang ditentukan oleh *mall*.
2. Penggunaan teknologi YOLOv8n dan CNN dalam deteksi kematangan pisang susu menawarkan solusi akurat dibandingkan dengan metode tradisional. YOLOv8n digunakan sebagai kemampuan mendeteksi objek *real-time*, sementara CNN sebagai analisis tingkat kematangan berdasarkan warna dan tekstur. Dalam YOLOv8n dan CNN dapat digunakan dalam membantu menentukan waktu panen yang tepat dan memastikan kualitas pisang susu yang memenuhi standar *mall*.
3. Pada aplikasi berbasis web dapat membantu untuk mendeteksi kematangan pisang susu secara otomatis, mengurangi risiko panen yang tidak tepat, serta meningkatkan daya saing produk di pasar. Aplikasi ini memastikan bahwa pisang susu memenuhi standar kualitas yang tinggi agar dapat memasuki *mall*.
4. Model YOLOv8n yang dilatih selama 100 *epoch* dengan ukuran *batch* 8 berhasil mengklasifikasikan kesegaran buah menjadi dua kategori: segar dan busuk, dengan akurasi rata-rata mencapai 88%. Pelatihan menunjukkan performa yang sangat baik, dengan akurasi mAP50 92% dan mAP50-95 66,1%.
5. Evaluasi menggunakan metrik umum menunjukkan tingkat *precision* sebesar 92,6% dan *recall* 86,9% pada *epoch* ke-100. Dengan demikian, rata-rata presisi keseluruhan model dalam mendeteksi kesegaran buah sekitar 89,75%. Dataset 200 *image* (70% *data training*, 20% *data validasi*, dan 10% *data testing*.)
6. Implementasi terhadap *framework Streamlite* dapat digunakan melalui tampilan *webapps user-friendly* dengan menggunakan *input* gambar melalui komputer lokal, tautan (url), serta video kamera *real-time*.

## 5. SARAN

Berdasarkan hasil penelitian ini, beberapa saran untuk meningkatkan deteksi kualitas pisang susu meliputi perluasan dataset dengan variasi gambar dari berbagai varietas dan kondisi buah, serta melanjutkan pelatihan model dengan lebih banyak *epoch* dan teknik *preprocessing* seperti augmentasi data. Pengujian model pada gambar dengan kondisi pencahayaan yang berbeda juga penting untuk memastikan konsistensi. Selain itu, integrasi teknologi pemrosesan citra canggih, seperti segmentasi objek dan peningkatan resolusi gambar, dapat

meningkatkan akurasi deteksi. Penggunaan metode lain dalam *computer vision*, seperti *Convolutional Neural Networks* (CNN) yang lebih dalam atau arsitektur seperti ResNet atau EfficientNet, dapat meningkatkan kemampuan ekstraksi fitur, mengurangi *overfitting*, dan mempercepat inferensi, sehingga meningkatkan kinerja model dalam kondisi yang lebih menantang. Dengan langkah-langkah ini, diharapkan dapat tercipta sistem deteksi yang lebih *robust* dan aplikatif, khususnya di sektor pertanian dan distribusi pangan.

## DAFTAR PUSTAKA

- [1] S. S. H. Ujang Rohman, "Optimalisasi Pemanfaatan Pisang Kepok Sebagai Produk Unggulan Desa Grinting Tulangan Sidoarjo Jawa Timur," *Jurnal Pengabdian Masyarakat*, vol. 2, no. 2, pp. 1-8, 2021.
- [2] P. B. H. J. Arif Hartono, "PELATIHAN PEMANFAATAN LIMBAH KULIT PISANG SEBAGAI BAHAN DASAR PEMBUATAN KERUPUK," *Jurnal Inovasi dan Kewirausahaan*, pp. 198-203, 2013.
- [3] F. A. Septian Hari Pratama, "KANDUNGAN GIZI, KESUKAAN, DAN WARNA BISKUIT SUBSTITUSI TEPUNG PISANG," *Journal of Nutrition College*, vol. 4, no. 2, pp. 252-258, 2015.
- [4] M. Indarto, "Deteksi Kematangan Buah Pisang Berdasarkan Fitur Warna Citra Kulit Pisang Menggunakan Metode Transformasi Ruang Warna HIS," *JUITA : Jurnal Informatika*, pp. 15-21, 2017.
- [5] E. M. N. I. R. S. A. L. K. R. Doni Andriansyah, "Klasifikasi Kualitas Buah Pisang Berdasarkan Waktu Panen dan Tingkat Kematangan Menggunakan Metode SVM & KNN," *SATIN –Sains dan Teknologi Informasi*, vol. 10, no. 1, pp. 147-156, 2024.
- [6] D. I. H. Rita Hayati, "PENGARUH TINGKAT KEMATANGAN DAN LAMA PENYIMPANAN TERHADAP KUALITAS PISANG MAS (*Musa acuminata Colla*)," *Jurnal Agrotropika*, pp. 145-155, 2023.
- [7] E. R. L. F. B. H. H. R. R. P. Budi Yanto, "PENERAPAN ALGORITMA DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK DALAM MENENTUKAN KEMATANGAN BUAH JERUK MANIS BERDASARKAN CITRA RED GREEN BLUE (RGB)," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, pp. 59-66, 2023.
- [8] E. S. N. Y. N. K. M. I. H. Fernandy Jupiter, "Implementasi Algoritma CNN dan YOLO untuk Mendeteksi Jenis Kendaraan pada Jalan Raya," *Jurnal Informasi dan Telematika*, vol. 14, no. 2, pp. 110-117, 2023.
- [9] A. I. Hanifah, "Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network," *Komputika: Jurnal Sistem Komputer*, vol. 12, no. 2, pp. 169-176, 2023.
- [10] M. F. H. E. S. O. Rendra Soekarta, "Klasifikasi Kematangan Buah Pisang Secara Real-Time Menggunakan Convolutional Neural Network Berbasis Android," *INSECT*, vol. 10, no. 01, pp. 11-20, 2024.
- [11] A. KHOTIBUL UMAM, "Perbandingan Metode ARIMA dan LSTM pada Prediksi Jumlah Pengunjung Perpustakaan," *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, vol. 8, no. 2, pp. 119-129, 2023.
- [12] S. D. A. N. I. N. C. K. AZIZAH AULIA RAHMAN, "Perbandingan Algoritma YOLOv4 dan Scaled YOLOv4 untuk Deteksi Objek pada Citra Termal," *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, vol. 7, no. 1, pp. 61-71, 2022.
- [13] S. M. R. M. A. B. K. D. D. A. A. S. A. Wulandari, "KLASIFIKASI KANDUNGAN NUTRISI BUAH PISANG BERDASARKAN FITUR TEKSTUR DAN WARNA LAB MENGGUNAKAN JARINGAN SYARAF TIRUAN BERBASIS PENGOLAHAN CITRA DIGITAL," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 11, no. 03, pp. 507-518, 2024.
- [14] D. S. M. M. Nurhaliza Juliyan Hayati, "OBJECT TRACKING MENGGUNAKAN ALGORITMA YOU ONLY LOOK ONCE (YOLO)v8 UNTUK MENGHITUNG KENDARAAN," *KOMPUTA : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 2, pp. 91-99, 2023.
- [15] A. H. Afifah Inas Hanifah, "Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network," *Komputika: Jurnal Sistem Komputer*, vol. 12, no. 2, pp. 169-176, 2023.
- [16] B. B. D. I. M. S. L. Yuma Akbar, "DETEKSI MICROSLEEP MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN SENSOR ESP32 PADA PENGEMUDI," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 7, no. 5, pp. 1668-1674, 2024.
- [17] N. H. D. R. S. H. Fani Nurona Cahya, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *Sistemasi: Jurnal Sistem Informasi*, vol. 10, no. 3, pp. 618-626, 2021.
- [18] J. T. I. Arie Ardiansyah, "Evaluasi Kinerja Model YOLOv8 dalam Deteksi Kesegaran Buah," *Jurnal JUPITER*, vol. 16, no. 2, pp. 357-368, 2024.
- [19] S. A. P. Dwi Normawati, "Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter," *Jurnal Sains Komputer & Informatika (J-SAKTI)*, vol. 5, no. 2, pp. 697-711, 2021.
- [20] S. R. Pratama, "Penerapan Deep Learning untuk Deteksi Penyakit pada Tanaman Padi Menggunakan Convolutional Neural Network (CNN)," *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 3, pp. 211-220, 2022.
- [21] R. W. Oktaviani, "Deteksi Kematangan Buah Mangga dengan Metode Deep Learning Menggunakan Convolutional Neural Networks," *Jurnal Informatika Universitas Satya Negara Indonesia*, vol. 13, no. 1, pp. 45-56, 2023.
- [22] A. S. Prasetya, "Penggunaan Metode Convolutional Neural Networks (CNN) pada Sistem Pendekripsi Kualitas Buah Apel," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 7, no. 2, pp. 72-83, 2021.
- [23] M. R. Suryani, "Implementasi Computer Vision untuk Pemantauan Kualitas Buah Jeruk di Industri Pertanian," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 5, no. 4, pp. 200-210, 2022.
- [24] T. H. Widodo, "Analisis Penerapan Model YOLO untuk Deteksi Kerusakan pada Buah Tomat," *Jurnal Ilmiah Komputer dan Informatika*, vol. 9, no. 1, pp. 67-79, 2021.