

## Deteksi Dan Klasifikasi Kondisi Telur Ayam Ras Berdasarkan Kerusakan Kerabang Menggunakan YOLO

Chandra Saputra<sup>1</sup>, Daniel Udjulawa<sup>2</sup>

<sup>1,2</sup>Informatika, Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang  
Jalan Rajawali no. 14, Palembang, Indonesia

e-mail: [chandrasaputra\\_2226250093@mhs.mdp.ac.id](mailto:chandrasaputra_2226250093@mhs.mdp.ac.id)<sup>1</sup>, [daniel@mdp.ac.id](mailto:daniel@mdp.ac.id)<sup>2</sup>

Received : November, 2025

Accepted : December, 2025

Published : December, 2025

### Abstract

Chicken farming is an important sector that provide animal protein sources, especially through egg production. The high demand for chicken eggs in Indonesia makes a fast and accurate sorting process to ensure quality very important. Until now, the sorting process has been done manually by human workers, which is time-consuming, costly, and prone to human error. This study aims to detect and classify the condition of chicken eggs based on shell damage using object detection algorithms such as YOLOv8 and YOLOv11. This experiment uses a dataset of 1280 images with four egg condition, intact, cracked or punctured, white, and soft. The dataset went through pre-processing, augmentation, training, validation, and testing stages. The results showed that both models were able to accurately detect and classify eggs, with YOLOv8 achieving a precision 0.997, a recall 1, an IoU 0.9345, mAP0.5 0.995, and mAP0.5-0.95 0.913, while YOLOv11 was slightly superior due to architectural improvements through the C3k2 and C2PSA blocks, achieving a precision 0.999, a recall 1, an IoU 0.9347, mAP0.5 0.995, and mAP0.5-0.95 0.912. Further research, is recommended using datasets with more complex backgrounds, varied lighting, and more diverse damage variations.

**Keywords:** egg detection, shell damage, YOLOv8, YOLOv11

### Abstrak

Peternakan ayam ras termasuk sektor penting yang menyediakan protein hewani, terutama melalui produksi telur. Tingginya permintaan telur ayam di Indonesia menjadikan proses pemilahan yang cepat dan akurat untuk memastikan kualitas sangat penting. Selama ini proses pemilahan dilakukan secara manual oleh tenaga manusia dengan waktu yang lama, serta biaya, dan rentan akan kesalahan manusia. Penelitian ini bertujuan untuk mendeteksi dan klasifikasi kondisi telur ayam ras berdasarkan kerusakan kerabang menggunakan algoritma deteksi objek seperti YOLOv8 dan YOLOv11. Penelitian ini menggunakan dataset sebanyak 1280 gambar dengan empat kondisi telur yaitu, utuh, retak atau berlubang, putih, dan lembut. Dataset tersebut melalui tahapan pre-processing, augmentasi, training, validasi, dan testing. Hasil pengujian menunjukkan kedua model mampu mendeteksi dan mengklasifikasi telur dengan tepat dimana YOLOv8 mendapatkan presisi 0.997, recall 1, IoU 0.9345, mAP0.5 0.995, dan mAP0.5-0.95 0.913, dan YOLOv11 sedikit lebih unggul karena peningkatan arsitektur melalui blok C3k2 dan C2PSA dengan presisi 0.999, recall 1, IoU 0.9347, mAP0.5 0.995, dan mAP0.5-0.95 0.912. Penelitian selanjutnya disarankan menggunakan dataset dengan latar yang lebih kompleks, pencahayaan beragam, serta variasi kerusakan yang lebih beragam.

**Kata Kunci:** deteksi telur, kerusakan kerabang, YOLOv8, YOLOv11

## 1. PENDAHULUAN

Peternakan merupakan sektor penting yang berfokus pada perawatan hewan untuk menghasilkan sumber pangan, seperti peternakan ayam yang menghasilkan telur [1]. Di Indonesia, lauk yang paling disukai dan memiliki permintaan yang tinggi pada masyarakat adalah telur ayam [2]. Telur ayam juga termasuk kedalam sumber protein yang kaya akan protein hewani, serta sangat populer dikalangan masyarakat. Menurut data pada tahun 2024 dari Badan Pusat Statistik (BPS), tingginya permintaan untuk kebutuhan akan telur ayam ras di Indonesia menyentuh hingga 6.238.956 ton [3]. Banyaknya permintaan telur ini menunjukkan pentingnya proses penyortiran telur sebelum proses distribusi dan penjualan, karena jumlah permintaan yang besar dibutuhkan pengelolaan yang baik agar kualitas tetap terjamin sebelum sampai ke tangan masyarakat [4].

Telur dengan kualitas yang baik akan memiliki nilai ekonomis yang lebih tinggi dan lebih menarik bagi konsumen di pasar [5]. Dalam memilih telur dengan kualitas yang baik pertama kali yang dilihat adalah kondisi cangkang atau kerabang yang tidak ada kerusakan kerabang [6] dan memiliki keseragaman warna pada kerabang yang dapat dijadikan titik ukur untuk kesehatan dan kandungan nutrisi dari ayam petelur [7]. Proses pengecekan kualitas telur yang dilakukan secara manual, yang mengandalkan pengecekan visual pada kondisi dan warna kerabang, membutuhkan waktu yang lama dan tenaga yang sangat banyak, serta beresiko akan kesalahan tenaga kerja [8]. Telur yang akan dipisah adalah telur dengan kondisi utuh maupun ada kerusakan kerabang seperti telur yang retak (berlubang), putih, dan yang tidak memiliki kerabang atau lembut [9]. Pemilihan dan penilaian kualitas kerabang ini secara tidak langsung akan mempengaruhi kualitas telur terutama daya simpan telur [10]. Umumnya, penilaian kualitas kerabang dilakukan secara manual oleh tenaga kerja manusia, dimana penilaian secara manual ini dinilai tidaklah efisien dari segi waktu dan biaya [11], sehingga dibutuhkan sebuah pengembangan yang memungkinkan untuk melakukan proses penyortiran yang cepat dan akurat.

Perkembangan teknologi yang pesat menjadikan adanya kemungkinan untuk melakukan proses penyortiran yang cepat dan tepat menggunakan bantuan dari *Artificial intelligence*. YOLO digunakan untuk mendeteksi objek yang sudah terbukti efektif [12]. YOLO atau *You Only Look Once* yang merupakan algoritma *deep learning* yang dirancang untuk melakukan deteksi objek secara *real-time* pada gambar maupun video [13]. Dengan adanya sistem deteksi dan klasifikasi otomatis membuat proses penyortiran menjadi lebih cepat, dan meringankan tenaga kerja manual, serta mengurangi kesalahan tenaga kerja [14].

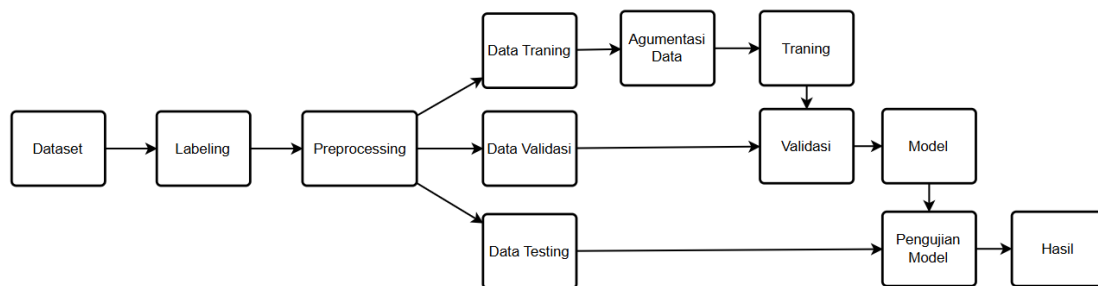
Penelitian oleh Sri Ayu Ningsih, Resti Ajeng Sutiani, Ni Made Sri Ulandari, dan Rizal Adi Saputra tahun 2024 melakukan Pendeteksi Kualitas Telur Ayam Berdasarkan Warna Cangkang menggunakan Algoritma YOLO dengan mAP@50 sebesar 95.05% [15]. Algoritma YOLO juga digunakan pada penelitian Isa Mahfudia, Ahmad Rozak Setia Nugraha, dan Azam Muzakhim Imammuddin tahun 2024 untuk mendeteksi telur yang menetas pada reptil [16]. Dalam penelitian Takyudin, Muhammad Sandi Rais, Jonni Adi Putra, Ali Hamsar tahun 2025 melakukan pengembangan sistem untuk mendeteksi dan estimasi ruas lubang pada jalan menggunakan YOLOv11 yang menghasilkan mAp50 mencapai 0.8, presisi 75.1%, *recall* 76.6%, F1-Score 75.8% [17].

Pada YOLO memiliki banyak versi yang bisa digunakan, tetapi pada penelitian ini berfokus pada penggunaan YOLOv8 dan YOLOv11 untuk mendeteksi dan klasifikasi kondisi telur ayam ras berdasarkan kerusakan kerabang. Data gambar telur ayam ras yang digunakan dalam penelitian ini diambil dan dikumpulkan langsung dari peternakan sehingga *dataset* lebih adaptif terhadap kondisi lokal serta dianotasi untuk melatih model yang digunakan. Setelah proses pelatihan selesai dilakukan proses evaluasi kinerja deteksi dan klasifikasi menggunakan dataset baru. Penelitian ini bertujuan untuk mengevaluasi ketepatan dan keakuratan dalam proses pemilihan telur dari kondisi kerusakan kerabang. Penelitian ini dimaksudkan untuk memberikan kontribusi terhadap pengembangan teknologi pemilihan atau penyortiran telur dalam sektor peternakan khususnya peternakan ayam ras, serta supaya pengelolaan telur ayam ras menjadi lebih baik.

## 2. METODE PENELITIAN

Pada penelitian ini untuk melakukan deteksi dan klasifikasi kondisi telur ayam ras berdasarkan kerusakan kerabang dilakukan melalui beberapa tahapan yang saling berkaitan sehingga membentuk sebuah penelitian yang sistematis. Dalam penelitian ini, terdiri dari tahapan yang saling terintegrasi mulai dari pengambilan

*dataset* berupa foto telur ayam ras bagian kerabang, *labeling* dan anotasi dilanjutkan dengan *pre-processing* supaya *dataset* menjadi lebih terstruktur, lalu pembagian data atau *split data*. Lalu tahapan augmentasi data ke data *training*. Setelah itu akan dilakukan *training* dan validasi, sehingga menghasilkan model, terakhir akan dilakukan pengujian model menggunakan data *testing*. Gambar 1 adalah tahapan-tahapan dalam penelitian.



Gambar 1. Tahapan-tahapan Dalam Penelitian

### 2.1 Pengumpulan *Dataset*

*Dataset* yang digunakan terdiri dari 5 kondisi telur dengan berbagai kerusakan kerabang (utuh, retak, putih, tidak ada kerabang, dan campuran antar kerusakan kerabang) sebanyak 256 gambar dari berbagai sudut pandang per kondisi dengan total 1280 gambar. Pengumpulan dilakukan menggunakan kamera

*handphone* Oppo f7 pro 16 MP dengan jarak objek ke kamera sejauh 10 cm. *Dataset* objek di ambil dengan pencahayaan di ruang terbuka dengan latar berwarna hitam yang menggunakan kain, dimana jika pada lingkungan peternakan nyata kain tersebut akan melapisi belt conveyor. Tabel 1 adalah sampel *dataset* telur yang digunakan.

Tabel 1: Sampel *Dataset* Telur

Foto	Keterangan
	Telur utuh dengan warna merah kecoklatan tanpa adanya lubang atau retak pada kerabang.
	Telur putih dengan warna kerabang yang putih tanpa adanya lubang atau retak pada kerabang.

Foto	Keterangan
	Telur retak dengan kondisi kerabang yang ada lubang.
	Telur lembut dengan kondisi tidak ada kerabang.
	Campuran keempat jenis kerabang pada telur.

## 2.2 Labeling dan anotasi

Proses *labeling* dan anotasi dilakukan menggunakan *platform roboflow* menjadi 4 kelas berdasarkan kondisi telur kerabang (utuh, retak, putih, dan tidak ada kerabang / lembut).

## 2.3 Pre-processing

Tahap *pre-processing* ini diterapkan ke semua *dataset* yang ada yaitu *Auto-Orient: Applied* yang berfungsi untuk menghilangkan data EXIF (*Exchangeable Image File*), supaya gambar yang dihasilkan pada *dataset* akan sama seperti yang ada di penyimpanan *disk*, lalu *preprocessing* kedua yaitu *resize: Stretch to 640×640* yang berfungsi untuk mengubah ukuran gambar [18].

## 2.4 Pembagian Data


Dataset dilakukan *split data* menjadi *training* 70%, validasi 20%, dan *testing* 10%. Dengan data *training* sebanyak 895 gambar, validasi 255 gambar, dan *testing* 130 gambar.

## 2.5 Augmentasi Data


Augmentasi data digunakan untuk memberikan variasi pada dataset dengan berbagai kondisi [19] seperti *flip: horizontal, vertical*, yang merupakan teknik augmentasi yang membalikkan citra yang dapat dilakukan baik secara horizontal maupun *vertical* [20] dan *90° rotate: clockwise, counter-clockwise, upside-down* yang teknik yang melakukan pemutaran citra dalam kelipatan 90° untuk menyesuaikan dengan perubahan orientasi objek [21]. Augmentasi ini hanya diterapkan pada data training menjadi 1790 gambar yang dilakukan setelah *split data*, dengan probabilitas kedua augmentasi sebesar 100%.

## 2.6 Evaluasi

Pada tahap evaluasi dibutuhkan *confusion matrix* atau matriks kebingungan yang merupakan tabel untuk membandingkan kinerja model dengan lebih detail. Gambar 2 adalah *confusion matrix* YOLOv8. Gambar 3 adalah *confusion matrix* YOLOv11.



Gambar 2. *Confusion matrix* YOLOv8



Gambar 3. *Confusion matrix* YOLOv11

Tahap evaluasi akan membandingkan kelas yang diprediksi dengan kelas sesungguhnya [22]. Metrik evaluasi yang digunakan adalah presisi, recall, IoU, dan mAP.

Presisi adalah ukuran yang menggunakan jumlah klasifikasi benar oleh sistem yang benar (TP) dengan jumlah seluruh data sesungguhnya yang benar untuk dibandingkan [23]. Persamaan 1 adalah rumus presisi.

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

Ket:

TP: jumlah data positif yang terklasifikasi dengan benar oleh sistem.

FP: jumlah data positif yang terklasifikasi dengan salah oleh sistem.

*Recall* adalah ukuran yang menggunakan jumlah klasifikasi benar oleh sistem yang benar (TP) dengan jumlah data relevan positif yang

sesungguhnya untuk dibandingkan [23].  
Persamaan 2 adalah rumus *recall*.

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (2)$$

Ket:

TP: jumlah data positif yang terklasifikasi dengan benar oleh sistem.

FN: jumlah data negatif yang terklasifikasi dengan salah oleh sistem.

IoU adalah metrik utama yang umum dipakai untuk mengevaluasi apakah suatu deteksi memenuhi ketentuan sebagai prediksi positif (TP) [24]. Persamaan 3 adalah rumus IoU.

$$IoU = \frac{A \cap B}{A \cup B} \quad (3)$$

Ket:

A: *bounding box* prediksi.

B: *bounding box* sebenarnya.

Metrik mAP adalah metrik yang mengitung rata-rata presisi pada berbagai nilai *recall* untuk tiap kelasnya [24]. mAP50 ini menggunakan batas ambang IoU sebesar 0.5 sedangkan mAP50-95 menggunakan batas ambang IoU dimulai dari 0.5 hingga 0.95. Persamaan 4 adalah rumus mAP.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

Ket:

I: kategori dalam *dataset*.



AP<sub>i</sub>: rata-rata presisi untuk kelas i.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Pre-processing

Proses ini menerapkan *Auto-Orient: Applied* yang memastikan hasil tetap sama dengan gambar yang diambil, dan *resize* menjadi ukuran 640×640. Tabel 2 adalah sampel dari hasil *pre-processing*.

Tabel 2: Sampel hasil *pre-processing*

Foto yang diproses	Hasil
	

#### 3.2 Hasil Augmentasi

Proses ini dilakukan supaya memperbanyak variasi dalam dataset dengan melakukan

beberapa macam variasi. Tabel 3 adalah contoh hasil augmentasi.

Tabel 3: Contoh hasil augmentasi






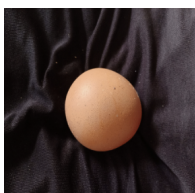


Foto yang diproses	Hasil	Proses
		<i>Flip: Vertical</i>
		<i>Flip: Horizontal</i>

Foto yang diproses	Hasil	Proses
		<i>90° rotate: clockwise</i>
		<i>90° rotate: counter-clockwise</i>
		<i>90° rotate: upside-down</i>

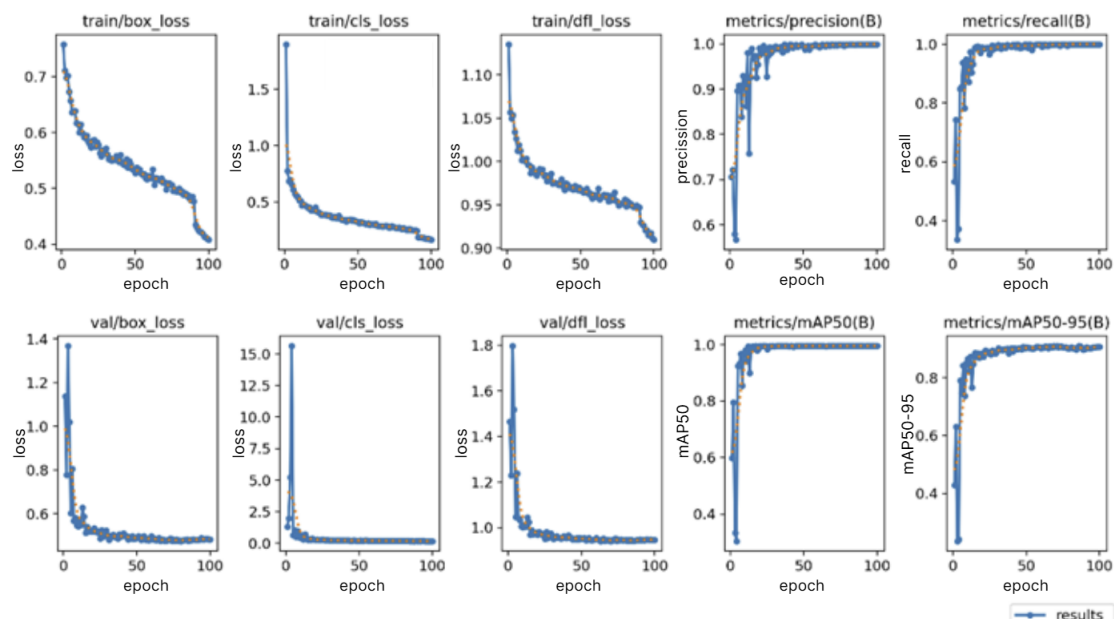
### 3.3 Hasil Model

Proses ini dilakukan menggunakan YOLOv8 dan YOLOv11 dengan masing-masing varian *s* (*small*). *Optimizer* yang digunakan adalah AdamW yang dapat mengatasi kekurangan Adam dalam mengelola regularisasi *weight decay* [25] dengan *learning rate* sebesar 0.00125, momentum dengan nilai 0.9 dan *weight decay* sebanyak 0.0005 yang merupakan nilai *default* dari *framework Ultralytics*. Pada YOLOv11 terdapat *Inference Time* sebesar 7ms

dengan 142 FPS (*Frame Per Second*), 9.429.340 params serta 21.6 GFLOPs, sedangkan YOLOv8 terdapat *Inference Time* sebesar 6ms dengan 166 FPS (*Frame Per Second*), 11.137.148 params serta 28.7 GFLOPs. Dalam proses *training batch size* yang digunakan adalah 32 dan *epoch* sebanyak 100. Gambar 4 adalah grafik *loss*, *presisi*, *recall*, dan mAP pada yolov8. Gambar 5 adalah grafik *loss*, *presisi*, *recall*, dan mAP pada yolov11. Tabel 4 adalah hasil evaluasi YOLOv8 dan YOLOv11.



Gambar 4. Grafik *loss*, presisi, *recall* dan mAP YOLOv8



Gambar 5. Grafik *loss*, presisi, *recall*, dan mAP YOLOv11

Tabel 4: Hasil evaluasi YOLOv8 dan YOLOv11

Evaluasi	YOLOv8	YOLOv11
Presisi	0.997	0.999
Recall	1	1
IoU	0.9345	0.9347
mAP@50	0.995	0.995
mAP@50-95	0.913	0.912

### 3.4 Pembahasan

Dari penelitian yang telah dilakukan untuk masing-masing model, dapat dilihat dari grafik yang ada pada gambar 4 dan 5, dimana saat melakukan *training* dan validasi fungsi *loss* sudah cukup baik ditandai dengan grafik yang menurun pada setiap *epoch*nya, walaupun pada validasi fungsi *loss* terdapat beberapa *epoch* dengan lonjakan tinggi di awal-awal grafik, yang berikutnya kembali menurun lagi. Sedangkan untuk hasil evaluasi metrik yang ada pada model juga tergolong baik karena dari grafik dapat dilihat terus terjadi peningkatan pada setiap *epoch*nya yang menandakan apabila mencapai nilai 1 akan semakin baik, walaupun ada yang terjadi penurunan yang curam. Dari grafik tersebut diperoleh nilai metrik evaluasi yang dapat dilihat pada tabel 4 dengan YOLOv11 mendapatkan hasil yang lebih baik dibandingkan dengan YOLOv8 walaupun hasil yang dihasilkan antara kedua metode tidak terlalu signifikan.

*Dataset* yang digunakan juga tergolong seimbang karena dari hasil presisi dan *recall* yang tinggi, dimana jika terjadi *dataset* yang *imbalance* maka presisi akan tinggi dan *recall* akan rendah [26]. Dari gambar 4 dan 5 pada grafik *train\_loss* dan *val\_loss* terjadi penurunan yang *smooth* serta pada grafik presisi dan *recall* terjadi peningkatan yang cukup stabil, dimana dari grafik-grafik tersebut menandakan tidak adanya terjadi *overfitting*. Pada penelitian ini juga terdapat *error* yang terjadi pada kelas tertentu seperti kelas retak, dimana jika keretakan yang halus maka dapat terlihat seperti kelas utuh.

Perbedaan hasil antara YOLOv8 dan YOLOv11 yang tidak terlalu signifikan ini dapat terjadi karena disebabkan *dataset* yang digunakan memiliki latar atau *background* yang tidak



terlalu kompleks dan ukuran objek yang cukup besar. Dimana YOLOv11 menghadirkan arsitektur yang unggul dalam melakukan deteksi objek berukuran kecil, pada berbagai kondisi pencahayaan dan lingkungan yang kompleks [27]. Sehingga dengan arsitektur YOLOv11 hampir tidak terlihat perbedaannya atau tidak signifikan dengan hasil dari YOLOv8. Nilai yang tidak signifikan dengan selisih presisi sebesar 0.002 dikatakan sepadan dengan beban komputasi dari yolov11 yang lebih ringan dibandingkan dengan yolov8 [28].

Dari hasil penggunaan YOLOv11 ini mendapatkan nilai yang sedikit lebih baik dikarenakan pada YOLOv11 terdapat beberapa penambahan dan pergantian blok, antara lain adanya blok C3k2, dan C2PSA yang berkontribusi dalam ekstraksi pemrosesan fitur supaya lebih efektif [29]. Blok C3k2 merupakan blok yang menggunakan dua konvolusi yang lebih kecil, alih-alih menggunakan satu konvolusi yang besar, sedangkan blok C2PSA berfungsi untuk meningkatkan fokus spasial dalam *feature maps* [30].




Dalam penelitian ini nilai recall yang menunjukkan 1 atau 100% terjadi karena

*dataset* yang terlalu mudah dimana objek yang ada terlalu jelas dengan ukuran yang besar dan penggunaan latar hitam yang membuat objek mudah untuk di deteksi.

Dalam perbandingan dengan penelitian terdahulu, dalam sistem deteksi dan klasifikasi menggunakan YOLOv11 dan YOLOv8 menunjukkan nilai yang baik. Penelitian oleh Sri Ayu Ningsih et al tahun 2024 menggunakan Algoritma YOLOv5 dengan mAP@50 sebesar 95.05%, sedangkan Takyudin et al tahun 2025 menggunakan YOLOv11 yang menghasilkan mAP@50 mencapai 80%. Model YOLOv11 dan YOLOv8 dalam penelitian ini mencapai mAP@50 sebesar 0.995 yang menunjukkan keunggulan YOLOv8 dan YOLOv11 saat menghadapi berbagai kondisi telur.

Tabel 5 merupakan pengujian untuk deteksi dan klasifikasi kondisi telur ayam ras berdasarkan kerusakan kerabang. Hasil dari pengujian ini menunjukkan bahwa, penggunaan YOLOv8 maupun YOLOv11 dalam deteksi dan klasifikasi kondisi telur ayam ras berhasil mendeteksi dan mengklasifikasikan dengan benar dengan nilai *confident score* yang tergolong tinggi diatas 0.90.

Tabel 5: Hasil pengujian YOLOv8 dan YOLOv11

Citra Input	YOLOv8	YOLOv11
		

#### 4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan terkait deteksi dan klasifikasi kondisi telur ayam ras berdasarkan kerusakan kerabang menggunakan metode YOLO dapat disimpulkan bahwa, penggunaan YOLOv8 dan YOLOv11 dapat melakukan deteksi dan klasifikasi dengan baik dengan peforma YOLOv11 sedikit lebih baik dibandingkan YOLOv8, meskipun sangat kecil, dimana *YOLOv8* mendapatkan presisi 0.997,

*recall* 1, IoU 0.9345, mAP0.5 0.995, dan mAP0.5-0.95 0.913, dan YOLOv11 mendapatkan presisi 0.999, *recall* 1, IoU 0.9347, mAP0.5 0.995, dan mAP0.5-0.95 0.912. Hal ini disebabkan penyempurnaan pada YOLOv11 dengan penggunaan blok C3k2 dan C2PSA yang berkontribusi dalam efisiensi ekstraksi fitur, namun keunggulan pada YOLOv11 belum terlalu terlihat signifikan apabila *dataset* dengan objek yang besar dan latar yang tidak kompleks.

Peforma antara kedua model menunjukkan bahwa karakteristik dari *dataset* memiliki pengaruh yang besar terhadap keberhasilan deteksi dan klasifikasi. Selain itu masih ditemukannya kesalahan pada kelas retak, terutama keterakan yang halus yang menyerupai kelas utuh, dimana hal ini menunjukkan keterbatasan model. Meskipun demikian, kedua model cukup andal dalam mendeteksi keempat jenis kondisi kerusakan kerabang pada telur ayam ras dan YOLOv11 menawarkan kinerja yang sedikit lebih unggul serta komputasi lebih ringan. Sebagai tindak lanjut dari penelitian ini, disarankan untuk menggunakan dataset yang memiliki latar kompleks, pencahayaan yang kurang atau diruangan tertutup, serta tingkat kerusakan kerabang yang lebih beragam.

#### DAFTAR PUSTAKA

- [1] H. H. A. Bani, "Aplikasi Good Farming Practices Pada Ayam Petelur Milik Bapak Jumain Di Desa Sekar Putih Kecamatan Junrejo, Kabupaten Malang," 2024.
- [2] S. Nugraha and Q. Aulia, "Image Classification Untuk Telur Ayam Menggunakan Smartphone Android Dengan Convolutional Neural Networks (Cnn)," *BERNAS J. Pengabd. Kpd. Masy.*, vol. 5, no. 2, pp. 1278–1285, 2024, [Online]. Available: <https://doi.org/10.31949/jb.v5i2.8187>
- [3] Badan Pusat Statistik Indonesia, *Peternakan Dalam Angka 2024*. 2024. [Online]. Available: <https://www.bps.go.id/id/publication/2024/12/20/522e07b24c7bbeb1c19b0a4e/peternakan-dalam-angka-2024.html>
- [4] R. R. M. Akbar, F. Rizal, and W. J. Shudiq, "Implementasi Algoritma Convolutional Neural Network (Cnn) Untuk Deteksi Kesegaran Telur Berbasis Android," *Jusikom J. Sist. Komput. Musirawas*, vol. 8, no. 1, pp. 1–10, 2023, doi: 10.32767/jusikom.v8i1.1949.
- [5] F. V. C. Rukmana, N. Lestari, N. Saqinnah, and I. Dewi, "Analisis Faktor Harga, Kualitas, dan Pendapatan terhadap Perilaku Pembelian Telur Ayam Ras: Kajian Literatur," *Kontan J. Ekon. Manaj. Dan Bisnis*, vol. 4, no. 2, pp. 1–9, 2025, doi: 10.59818/kontan.v4i2.1709.
- [6] N. Wakur, E. S. Tangkere, L. J. Lambey, and Y. H. S. Kowel, "Kondisi fisik kerabang telur ayam ras petelur cokelat di Pasar Pinasungkulan Manado," *Zootec*, vol. 41, no. 1, p. 1, 2021, doi: 10.35792/zot.41.1.2021.31485.
- [7] M. Mujiono, A. K. Nalendra, and E. H. Candrapuspa, "Penerapan Logika Fuzzy pada Alat Pendeteksi Kualitas Telur Berbasis Mikrokontroler Arduino," *Gener. J.*, vol. 7, no. 1, pp. 8–13, 2023, doi: 10.29407/gj.v7i1.17239.
- [8] A. L. Affandy, M. Risal, S. Sabridah, R. Riswanda, and S. Syahrizan, "Pemanfaatan Sensor Ldr Dalam Memilah Telur Ayam Berbasis Arduino Mega," *J. It*, vol. 13, no. 3, pp. 85–95, 2022, doi: 10.37639/jti.v13i3.296.
- [9] T. Aprianis, "Analisis Pengendalian Mutu Telur Ayam Ras Dalam Upaya Meminimumkan Tingkat Kerusakan Di Cv Gunung Harta Farm," *Perpust. Repos.*, 2022, [Online]. Available: <https://repository.polinela.ac.id/3205/>
- [10] W. Bilyaro, D. Lestari, and A. S. Endayani, "Identifikasi Kualitas Internal Telur Dan Faktor Penurunan Kualitas Selama Penyimpanan," *J. Agric. Anim. Sci.*, vol. 1, no. 2, pp. 55–62, 2021, doi: <https://doi.org/10.47637/agrimals.v1i2.418>.
- [11] M. Sholeh and R. P. Astutik, "Rancang Bangun Sistem Otomatis Untuk Penghitungan, Pemilahan, Dan Penilaian Kualitas Telur Dengan Fitur Pengiriman Informasi Ke Whatsapp," *E-Link J. Tek. Elektro dan Inform.*, vol. 20, no. 1, pp. 89–96, 2025, doi: 10.30587/e-link.v20i1.10096.
- [12] R. Rudiansyah, A. A. Sunarto, and D. Indrayana, "Implementasi Algoritma Yolo Untuk Identifikasi Jenis Tanaman Aglaonema," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3S1, 2024, doi: 10.23960/jitet.v12i3s1.5209.
- [13] O. Alfiano and dan Santi Rahayu, "Implementasi Algoritma Deep Learning Yolo (You Only Look Once) Untuk Deteksi Kualitas Kentang Segar Dan Busuk Secara Real Time," *JORAPI J. Res. Publ. Innov.*, vol. 2, no. 3, pp. 2470–2478, 2024, [Online]. Available: <https://jurnal.portalpublikasi.id/index.php/JORAPI/index>
- [14] L. Sihombing and A. Sinambela, "Inovasi Sistem Penyortiran Buah Dengan

- Pemanfaatan Internet of Things,” *Indones. J. Media Informatics*, vol. [Volume, j, no. [Nomor, jika ada], p. [Halaman awal, jika ada]-[Halaman akhir, ada], 2025, [Online]. Available: <https://ojs.gelcipnus.org/index.php/ijmi/article/view/52>
- [15] S. A. Ningsih, R. A. Sutiani, N. M. S. Ulandari, and R. A. Saputra, “Penerapan Algoritma Yolo Untuk Mendeteksi Kualitas Telur Ayam Berdasarkan Warna Cangkang,” *Method. J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 2, pp. 35–39, 2024, doi: 10.46880/mtk.v10i2.3062.
- [16] I. Mahfudi, A. R. Setia Nugraha, and A. Muzakhim Imammuddin, “Implementasi You Only Look Once (YOLO) Menggunakan Metode Deep Learning dalam Mendeteksi Telur Menetas pada Reptil,” *J. Apl. Sains, Informasi, Elektron. dan Komput.*, vol. 6, no. 2, pp. 177–184, 2024.
- [17] T. Takyudin, M. S. Rais, J. A. Putra, and A. Hamsar, “Metode Deteksi dan Estimasi Luas Lubang Jalan Menggunakan Deep Learning Berbasis YOLOv11,” *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 2, pp. 6786–6790, 2025.
- [18] D. W. Permatasari and R. E. Putra, “Implementasi Algoritma YOLO11 dalam Mendeteksi Spesies Ikan Laut Komersial secara Real Time untuk Sistem Penyortiran Ikan,” *J. Informatics Comput. Sci.*, vol. 06, pp. 924–931, 2025.
- [19] A. I. Pradana, H. Harsanto, and W. Wijiyanto, “Deteksi Rambu Lalu Lintas Real-Time di Indonesia dengan Penerapan YOLOv11: Solusi Untuk Keamanan Berkendara,” *J. Algoritm.*, vol. 21, no. 2, pp. 145–155, 2024, doi: 10.33364/algoritma/v.21-2.2106.
- [20] F. F. Masaugi, F. Yanto, E. Budianita, S. Sanjaya, and F. Syafria, “DEEP LEARNING MENGGUNAKAN ALGORITMA XCEPTION DAN AUGMENTASI FLIP PADA KLASIFIKASI KEMATANGAN SAWIT,” *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 4, no. 6, 2024, doi: <https://doi.org/10.30865/klik.v4i6.1938>.
- [21] N. A. Putra and A. K. Wardhana, “Image-Based Classification of Healthy and Unhealthy Goats Using ResNet-18 Deep Learning Model,” vol. 9, no. 5, 2025.
- [22] Y. Syifa Cendikia, I. Taufik, A. Arnita, Z. Indra, and C. Chairunisah, “Menentukan Warna Make Up Yang Cocok Berdasarkan Jenis Skintone Pada Citra Wajah Menggunakan Naive Bayes Classifier,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 1, pp. 816–823, 2024, doi: 10.36040/jati.v9i1.12494.
- [23] A. Sentimen, T. Layanan, A. Modesta, B. Husna, M. Binti Husna, and W. Gata, “Analisis Sentimen Terhadap Layanan Aplikasi Jenius di Media Sosial Menggunakan Alogritma Long Short-Term Memory,” pp. 793–805, 2016.
- [24] L. K. Ramadhani and B. N. Widyaningrum, “Implementation of YOLO v11 for Image-Based Litter Detection and Classification in Environmental Management Efforts,” vol. 9, no. 3, pp. 617–624, 2025.
- [25] P. Paru-paru, N. S. Mahajaya, P. Desiana, W. Ayu, and R. R. Huizen, “Pengaruh Optimizer Adam , AdamW , SGD , dan LAMB terhadap Model Vision Transformer pada Klasifikasi,” pp. 818–823, 2024.
- [26] E. Tangkelobo, W. Mayaut, H. Listanto, I. Binanto, and N. F. Sianipar, “Perbandingan Algoritma Klasifikasi Random Forest , Gaussian Naive Bayes , dan K-Nearest untuk Data Tidak Seimbang dan Data yang diseimbangkan dengan metode Random Undersampling pada dataset LCMS Tanaman Keladi Tikus,” 2023.
- [27] A. Luthfi, E. M. Yuniarno, and S. M. S. Nugroho, “Menghitung Luas Bangun Datar pada Papan Tulis Menggunakan Yolo,” *J. Tek. ITS*, vol. 11, no. 3, 2022, doi: 10.12962/j23373539.v11i3.92620.
- [28] J. Bento, T. Paixão, and A. B. Alvarez, “Performance Evaluation of YOLOv8 , YOLOv9 , YOLOv10 , and YOLOv11 for Stamp Detection in Scanned Documents,” 2025.
- [29] R. Khanam and M. Hussain, “YOLOv11: An Overview of the Key Architectural Enhancements,” vol. 2024, pp. 1–9, 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [30] P. Hidayatullah, N. Syakrani, M. R. Sholahuddin, T. Gelar, and R. Tubagus, “YOLOv8 to YOLO11: A Comprehensive Architecture In-depth Comparative Review,” 2025, [Online]. Available: <http://arxiv.org/abs/2501.13400>

