

Evaluasi Kinerja Arsitektur Ringan YOLOv11n dalam Deteksi Kecacatan Fisik Cangkang Telur untuk Pendukung Sistem Penjaminan Mutu

Caesar Gian Indrarizky*, Figo Mandala, Aisy Hafidzah Fadlillah

Fakultas Informatika, Program Studi S1 Informatika, Telkom University, Bandung, Indonesia
Email: ^{1,*}caesargian@student.telkomuniversity.ac.id, ²figomandala@student.telkomuniversity.ac.id,
³aisyfadlillah@student.telkomuniversity.ac.id
Email Penulis Korespondensi: caesargian@student.telkomuniversity.ac.id

Abstrak—Kecacatan fisik pada cangkang telur berpotensi menurunkan kualitas produk serta memperbesar peluang kontaminasi saat proses distribusi dan konsumsi. Inspeksi secara manual dinilai memiliki kelemahan dari segi konsistensi, efisiensi, dan ketahanan fisik operator, khususnya pada volume produksi berskala besar. Oleh karena itu, studi ini bertujuan untuk mengevaluasi efektivitas arsitektur ringan YOLOv11n dalam mendeteksi anomali fisik cangkang telur guna mendukung otomatisasi sistem penjaminan mutu. Dataset penelitian memuat 968 citra telur yang diklasifikasikan menjadi kelas *Damaged* dan *Normal*, menghasilkan total 1.294 anotasi objek. Sebagai upaya menekan risiko *overfitting* yang dipicu oleh minimnya data dan ketimpangan kelas, diterapkan prapemrosesan berupa perubahan ukuran citra menjadi 640×640 piksel serta teknik augmentasi data spasial secara ekstensif (pembalikan horizontal, penyesuaian warna HSV, translasi, penskalaan, *mosaic augmentation*, *random erasing*, dan *auto augmentation*). Model dilatih dalam 100 *epoch* menggunakan bobot pra-latih YOLOv11n melalui skema *5-Fold Cross Validation*. Pengukuran kinerja dievaluasi menggunakan metrik *precision*, *recall*, *F1-Score*, *mAP50*, dan *mAP50-95*. Hasil eksperimen membuktikan bahwa model mampu mencatatkan nilai rata-rata *precision* 0,95, *recall* 0,93, *F1-Score* 0,94, *mAP50* 0,96, dan *mAP50-95* 0,92. Kontribusi utama dari penelitian ini adalah pembuktian secara empiris bahwa integrasi algoritma ringan YOLOv11n dengan augmentasi data spasial mampu menjadi solusi yang sangat akurat sekaligus efisien secara komputasional dalam mengatasi masalah ketimpangan kelas pada dataset berskala kecil. Secara keseluruhan, YOLOv11n menampilkan performa deteksi yang menjanjikan, meskipun pengujian terkait metrik kecepatan inferensi seperti latency dan FPS pada perangkat keras fisik secara langsung masih membutuhkan kajian pada riset selanjutnya.

Kata Kunci: Computer Vision; Deep Learning; Deteksi Cacat Telur; Quality Assurance; YOLOv11n

Abstract—Physical defects in eggshells can degrade product quality and increase the risk of contamination during distribution and consumption. Manual inspection has limitations regarding consistency, efficiency, and operator endurance, especially at a large production scale. Therefore, this study aims to evaluate the effectiveness of the lightweight YOLOv11n architecture in detecting physical anomalies in eggshells to support automated quality assurance systems. The research dataset contains 968 egg images classified into *Damaged* and *Normal* classes, yielding a total of 1,294 object annotations. To mitigate the risk of overfitting triggered by limited data and class imbalance, pre-processing was applied by resizing images to 640×640 pixels, alongside extensive spatial data augmentation techniques (horizontal flip, HSV adjustments, translation, scaling, *mosaic augmentation*, *random erasing*, and *auto augmentation*). The model was trained for 100 epochs using YOLOv11n pre-trained weights through a *5-Fold Cross Validation* scheme. Performance was evaluated using precision, recall, F1-Score, mAP50, and mAP50-95 metrics. The experimental results prove that the model achieved an average precision of 0.95, recall of 0.93, F1-Score of 0.94, mAP50 of 0.96, and mAP50-95 of 0.92. The primary contribution of this research is the empirical evidence that integrating the lightweight YOLOv11n algorithm with spatial data augmentation provides a highly accurate and computationally efficient solution to overcome class imbalance in small-scale datasets. Overall, YOLOv11n demonstrates promising detection performance, although further evaluation regarding inference speed metrics such as latency and FPS on direct physical hardware requires further investigation.

Keywords: Computer Vision; Deep Learning; Egg Defect Detection; Quality Assurance; YOLOv11n

1. PENDAHULUAN

Tingkat kualitas dan keamanan pangan pada komoditas telur unggas memiliki ketergantungan absolut terhadap ketelitian proses inspeksi pasca panen. Cacat fisik berukuran mikroskopis sekalipun pada permukaan cangkang dapat membuka celah kontaminasi patogen berbahaya yang mengancam kesehatan konsumen sekaligus memperpendek masa simpan produk secara drastis [1], [2]. Industri konvensional umumnya masih mengandalkan tenaga manusia melalui metode peneropongan cahaya untuk menyortir kecacatan tersebut. Akan tetapi, pendekatan manual ini dinilai tidak relevan untuk diterapkan pada volume produksi berskala masif karena sangat rentan terhadap kelelahan visual, inkonsistensi keputusan, dan inefisiensi waktu operasional [1].

Sebagai respons terhadap tantangan tersebut, penetrasi teknologi kecerdasan buatan melalui cabang visi komputer telah mendorong transisi besar menuju otomasi cerdas di berbagai sektor agrikultur [3], [4]. Penggunaan arsitektur *Convolutional Neural Network* yang diperkuat dengan mekanisme atensi telah terbukti secara empiris mampu mengekstraksi fitur anomali visual yang sangat presisi pada cangkang telur [5], [6], [7]. Keandalan metode jaringan saraf ini juga diakui secara luas dalam memilah kecacatan struktural produk di lingkungan manufaktur yang sangat kompleks [8], [9], [10].

Meskipun model klasifikasi standar menawarkan akurasi tinggi, implementasinya pada sistem sabuk konveyor pabrik kerap terkendala oleh beban komputasi yang berat. Oleh karena itu, keluarga algoritma pendeteksi objek satu tahap seperti *You Only Look Once* (YOLO) lebih direkomendasikan karena kemampuannya memproses bingkai gambar secara waktu nyata [11], [12]. Berbagai riset terdahulu telah sukses menguji coba varian YOLO untuk memantau integritas produk agrikultur secara efisien [13], [14], [15], [16] termasuk dalam mengidentifikasi kerusakan spesifik pada telur

unggas [17], [18].

Terkait dengan rekayasa otomasi pendeteksi kecacatan telur dan produk agrikultur, beberapa penelitian terdahulu telah berupaya mengimplementasikan varian jaringan saraf tiruan. Huang dkk. sukses memanfaatkan algoritma YOLOv5 untuk mendeteksi kerusakan pada telur yang belum dicuci dengan tingkat akurasi 96,4 persen [11]. Di sisi lain, Zhao dkk. menggunakan pendekatan YOLOv7 untuk mengidentifikasi dan menghitung telur pada peternakan kandang baterai [17]. Pada komoditas yang berbeda, arsitektur generasi kedelapan juga telah dieksplorasi secara luas, seperti pada studi Chen dkk. yang menerapkan varian YOLOv8 untuk pengenalan anomali permukaan produk [13], serta penelitian Luo dkk. yang menguji keandalan YOLOv8n pada lini produksi talas secara waktu nyata [14].

Meskipun keempat studi literatur tersebut telah membuktikan keandalan keluarga algoritma YOLO, masih terdapat celah riset (research gap) yang krusial. Arsitektur generasi sebelumnya (seperti varian v5, v7, maupun v8) kerap dihadapkan pada dilema komputasional; di mana upaya peningkatan presisi deteksi sering kali harus ditebus dengan pembengkakan ukuran parameter bobot model yang memperlambat laju inferensi sistem [19]. Lebih lanjut, metodologi penanganan ketidakseimbangan kelas (class imbalance) pada dataset cacat mikroskopis yang berukuran sangat kecil belum dieksplorasi secara mendalam. Untuk menjembatani celah tersebut, YOLOv11 hadir menawarkan solusi teknis yang radikal melalui restrukturisasi blok ekstraksi fitur menggunakan modul C3k2 yang jauh lebih ramping namun memiliki akurasi lokalisasi superior [20]. Oleh karena itu, kontribusi utama dari penelitian ini adalah menyajikan kerangka kerja yang mengintegrasikan arsitektur taringan YOLOv11 (YOLOv11n) dengan teknik augmentasi spasial komprehensif, guna menghasilkan sistem otomasi penjaminan mutu yang tidak hanya akurat dalam memitigasi peringatan palsu pada data kecil, namun juga sangat efisien secara komputasi.

2. METODOLOGI PENELITIAN


2.1 Kerangka Dasar Penelitian

Penelitian ini merupakan jenis penelitian eksperimental kuantitatif yang berfokus pada ranah visi kom-puter dan kecerdasan buatan. Objek utama dalam penelitian ini adalah dataset citra cangkang telur publik yang dikategorikan ke dalam dua kelas, yaitu kelas telur cacat dan kelas telur normal. Hipotesis dasar dari penelitian ini adalah bahwa penerapan algoritma deteksi objek satu tahap terbaru, yakni YOLOv11n, yang dikombinasikan dengan teknik pra-pemrosesan augmentasi data, mampu memberikan performa deteksi yang baik untuk mengenali anomali cangkang.

Dalam kerangka penelitian ini, terdapat dua jenis variabel utama yang dikaji. Variabel independen atau variabel bebas meliputi penggunaan arsitektur YOLOv11n serta penerapan teknik augmentasi data spasial. Sementara itu, variabel dependen atau variabel terikat yang diukur sebagai hasil eksperimen meliputi berbagai metrik kinerja komputasi standar, seperti persentase presisi, perolehan, rata-rata mean Average Precision, dan skor harmonis F1. Pengujian perangkat lunak dilakukan sepenuhnya menggunakan akselerator grafis awan untuk menyimulasikan lingkungan komputasi berkinerja tinggi.

2.2 Tahapan Penelitian

Untuk memastikan bahwa eksperimen berjalan secara sistematis dan terstruktur, penelitian ini meng-adopsi prosedur alur kerja rekayasa kecerdasan buatan yang terdiri dari serangkaian langkah operasional. Gambaran utuh mengenai tahapan tersebut divisualisasikan melalui bagan alur kerja sistem.



Gambar 1. Kerangka Alur Kerja dan Tahapan Penelitian.

Merujuk pada Gambar 1, tahapan operasional dimulai dengan pengumpulan data. Penelitian ini memanfaatkan dataset citra cangkang telur publik yang terdiri dari kelas cacat dan kelas normal. Setelah data diakuisisi, langkah selanjutnya adalah tahap pra-pemrosesan. Seluruh citra diubah ukurannya secara seragam menjadi resolusi 640×640 piksel agar sesuai dengan standar lapisan masukan arsitektur jaringan saraf. Mengingat adanya ketimpangan distribusi jumlah sampel di mana kelas cacat sangat mendominasi, teknik augmentasi data spasial diterapkan secara intensif. Modifikasi perluasan dataset melalui rotasi dan pembalikan citra ini merupakan teknik standar yang terbukti krusial dalam menyeimbangkan porsi bobot jaringan serta memperkuat kemampuan generalisasi model pendeteksi anomali [6]. Tahap krusial berikutnya adalah pelatihan model komputasi. Arsitektur yang dipilih untuk eksperimen ini adalah varian taringan dari iterasi kesebelas, yakni YOLOv11n. Pemilihan algoritma mutakhir ini di-dasarkan pada kapabilitasnya yang sangat kompetitif dalam memberikan tingkat presisi tinggi sekaligus memangkas beban memori komputasi [19]. Eksperimen komputasi dilakukan menggunakan akselerator grafis awan selama seratus putaran pelatihan. Untuk memastikan keandalan hasil evaluasi serta mencegah bias acak yang mungkin timbul, skenario pelatihan dieksekusi secara ketat menggunakan metode pengujian validasi silang lima lipatan. Pada tahap akhir, keluaran dari model dievaluasi menggunakan metrik kinerja standar industri guna mendapatkan landasan analisis empiris yang sah untuk

penarikan kesimpulan.

2.3 Pengumpulan dan Pra-Pemrosesan Data

Penelitian ini memanfaatkan dataset citra cangkang telur publik yang terdiri dari dua kelas utama, yaitu cacat dan normal. Penggunaan citra RGB standar dari dataset semacam ini sejalan dengan efisiensi pengenalan pola yang telah diuji pada penelitian visi komputer bidang agrikultur sebelumnya [5], [11]. Dataset yang digunakan berasal dari Kaggle dengan nama Damaged and Normal Eggshells [20]. Dataset terdiri atas 968 citra telur yang terbagi ke dalam dua kelas, yaitu Damaged dan Normal. Secara keseluruhan terdapat 1.294 anotasi objek, yang terdiri atas 977 objek Damaged dan 317 objek Normal. Dataset telah dibagi menjadi 679 citra data pelatihan, 145 citra data validasi, dan 144 citra data pengujian.

Pada tahap pra-pemrosesan, seluruh citra diubah ukurannya menjadi resolusi 640×640 piksel agar sesuai dengan ukuran masukan YOLOv11n. Anotasi dataset menggunakan format YOLO, yaitu setiap objek direpresentasikan melalui label kelas dan koordinat bounding box yang telah dinormalisasi. Kesesuaian antara label, posisi bounding box, dan objek telur pada citra diperiksa untuk mengurangi risiko kesalahan anotasi selama proses pelatihan.

Mengingat adanya ketimpangan distribusi jumlah objek antara kelas Damaged dan Normal, augmentasi data diterapkan untuk mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model. Augmentasi yang digunakan mencakup horizontal flip, perubahan warna HSV, translasi, perubahan skala, mosaic augmentation, random erasing, dan auto augmentation. Penerapan augmentasi ini merupakan strategi yang umum digunakan untuk memperluas variasi data latih dan memperkuat kemampuan generalisasi model pendeteksi objek [6], [13], [16].

2.4 Arsitektur dan Skenario Pelatihan

Arsitektur yang dipilih untuk eksperimen ini adalah varian teringan dari YOLOv11, yakni YOLOv11n. Pemilihan algoritma mutakhir ini didasarkan pada kapabilitasnya yang sangat kompetitif dalam memberikan tingkat presisi tinggi sekaligus memangkas beban latensi inferensi, sehingga menjadikannya sangat ideal untuk diterapkan pada skenario lini produksi berkecepatan tinggi [19]. Eksperimen dilakukan menggunakan akselerator grafis awan selama 100 putaran pelatihan. Untuk memastikan keandalan hasil evaluasi serta mencegah bias yang mungkin timbul dari variasi data latih, skenario pelatihan dieksekusi secara ketat menggunakan metode pengujian validasi silang lima lipatan.

Secara arsitektural, YOLOv11n merupakan model deteksi objek satu tahap yang melakukan proses lokalisasi objek dan klasifikasi kelas dalam satu alur pemrosesan. Arsitektur YOLO secara umum terdiri atas tiga komponen utama, yaitu backbone, neck, dan detection head. Backbone berfungsi untuk mengekstraksi fitur visual dari citra masukan, neck berperan dalam menggabungkan fitur pada beberapa skala, sedangkan detection head menghasilkan prediksi berupa kelas objek dan koordinat bounding box. Pada penelitian ini, karakteristik ringan dari YOLOv11n dimanfaatkan untuk mengevaluasi kemampuan deteksi kecacatan fisik cangkang telur dengan tetap mempertimbangkan efisiensi komputasi.

Pelatihan model dilakukan menggunakan bobot awal yolo11n.pt dengan pendekatan transfer learning. Seluruh citra masukan diubah ke ukuran 640×640 piksel. Model dilatih selama 100 epoch dengan batch size sebesar 16, optimizer AdamW, learning rate awal sebesar 0,001, weight decay sebesar 0,0005, patience sebesar 20, dan seed sebesar 42. Pelatihan dilakukan pada lingkungan Google Colab menggunakan GPU Tesla T4. Konfigurasi parameter yang sama diterapkan pada setiap fold agar proses pelatihan dan evaluasi berlangsung secara konsisten.

Pada skema 5-Fold Cross Validation, dataset dibagi menjadi lima subset sehingga setiap subset memperoleh kesempatan sebagai data validasi, sedangkan subset lainnya digunakan sebagai data pelatihan. Pada setiap fold, jumlah data pelatihan berkisar antara 774 hingga 775 citra, sedangkan data validasi berkisar antara 193 hingga 194 citra. File konfigurasi data.yaml disesuaikan agar memuat dua kelas target, yaitu Damaged dan Normal, serta menunjuk direktori citra dan label yang sesuai pada setiap fold. Dengan skema ini, evaluasi model tidak hanya bergantung pada satu pembagian data, tetapi mencerminkan performa model pada beberapa variasi data latih dan validasi.

2.5 Metrik Evaluasi

Untuk mengukur kinerja dan keandalan model YOLOv11n secara kuantitatif, penelitian ini menggunakan beberapa metrik evaluasi standar dalam ranah pengenalan objek. Perhitungan metrik ini didasarkan pada perhitungan nilai *True Positive* (TP), *False Positive* (FP), dan *False Negative* (FN) yang diekstraksi dari hasil pengujian.

a. Presisi (*Precision*)

Presisi mengukur tingkat keakuratan model dalam memprediksi kelas positif. Metrik ini menunjukkan seberapa banyak tebakan benar dari keseluruhan tebakan yang dianggap positif oleh model. Persamaan untuk menghitung presisi adalah sebagai berikut:

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

b. Perolehan (*Recall*)

Recall mengukur sensitivitas atau kemampuan model dalam mendeteksi dan melokalisasi seluruh objek target yang sebenarnya ada di dalam kumpulan data gambar:

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



c. Skor Harmonik (*F1-Score*)

Skor F1 merupakan metrik turunan yang menghitung nilai rata-rata antara Presisi dan *Recall*. Metrik ini sangat krusial digunakan untuk mengevaluasi kinerja jaringan saraf pada kasus di mana dataset memiliki ketimpangan jumlah kelas (*class imbalance*):

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

d. Mean Average Precision (mAP)

mAP merupakan metrik paling komprehensif untuk mengevaluasi kinerja pendeteksian kotak pembatas (*bounding box*). mAP dihitung dengan mencari nilai rata-rata dari *Average Precision* (AP) untuk seluruh kelas target pada ambang batas (*threshold*) yang ditetapkan:


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

di mana N mewakili jumlah total kelas yang dievaluasi (dalam hal ini dua kelas: cacat dan normal), serta AP_i adalah nilai rata-rata presisi murni pada kelas ke- i .

3. HASIL DAN PEMBAHASAN

3.1 Hasil Evaluasi Model

Berdasarkan Gambar 2, model YOLOv11 yang dilatih menggunakan skema *5-Fold Cross Validation* menunjukkan performa yang konsisten pada seluruh *fold* pengujian. Nilai *precision*, *recall*, *mAP50*, dan *mAP50-95* yang diperoleh pada setiap *fold* berada pada rentang yang relatif berdekatan, menunjukkan bahwa model memiliki tingkat generalisasi yang baik terhadap data yang digunakan. Rata-rata nilai *precision*, *recall*, *mAP50*, dan *mAP50-95* yang diperoleh berturut-turut sebesar 0,95, 0,93, 0,96, dan 0,92. Selain itu, model juga memperoleh nilai *F1-Score* sebesar 0,94 yang menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Secara keseluruhan, hasil tersebut menunjukkan bahwa model mampu mendeteksi serta mengklasifikasi objek telur normal maupun telur cacat dengan performa yang tinggi.



Gambar 2. Rata-rata metrik evaluasi hasil 5-Fold Cross Validation

3.2 Analisis Hasil


Nilai *precision* yang tinggi menunjukkan bahwa sebagian besar prediksi model sesuai dengan kelas sebenarnya, sedangkan nilai *recall* yang berada di atas 0,87 pada seluruh *fold* menunjukkan bahwa model mampu menemukan sebagian besar objek telur pada data uji. Selisih nilai *precision* dan *recall* yang relatif kecil mengindikasikan bahwa model memiliki keseimbangan antara kemampuan mendeteksi objek dan meminimalkan kesalahan prediksi.

Nilai *mAP50* yang berada di atas 0,96 menunjukkan bahwa model memiliki kemampuan lokalisasi objek yang baik pada ambang batas *Intersection over Union* (IoU) 0,5. Sementara itu, nilai *mAP50-95* yang tetap berada di atas 0,91 menunjukkan bahwa performa model masih stabil ketika dievaluasi menggunakan rentang IoU yang lebih ketat. Meskipun demikian, hasil ini perlu ditafsirkan secara hati-hati karena dataset yang digunakan masih terbatas, sehingga pengujian pada data eksternal dan kondisi citra yang lebih bervariasi tetap diperlukan.

3.3 Analisis Confusion Matrix

Berdasarkan Gambar 3, model YOLOv11 mampu mengklasifikasikan sebagian besar data pada kedua kelas dengan benar. Kelas *Damaged* memiliki tingkat klasifikasi yang tinggi dengan nilai sekitar 95%, sedangkan kelas *Normal* mencapai sekitar 97%. Hasil ini menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan telur normal dan telur cacat. Meskipun masih terdapat sejumlah kecil kesalahan klasifikasi, proporsinya relatif rendah dibandingkan jumlah

keseluruhan data uji. Oleh karena itu, model dapat dikatakan memiliki performa yang stabil dan mampu melakukan proses klasifikasi dengan performa yang tinggi pada kedua kategori telur.



Gambar 3. Confusion matrix ternormalisasi hasil klasifikasi model YOLOv11.


3.4 Hasil Deteksi pada Data Uji

Berdasarkan Gambar 4, model YOLOv11 berhasil mendeteksi objek telur cacat dengan tingkat kepercayaan sebesar 0,97. Posisi objek yang diprediksi juga sesuai dengan ground truth sehingga menunjukkan kemampuan lokalisasi objek yang baik pada kelas *damaged*. Berdasarkan Gambar 5, model YOLOv11 mampu mendeteksi beberapa objek telur normal secara bersamaan dengan tingkat kepercayaan yang tinggi. Seluruh objek pada citra berhasil dilokalisasi menggunakan *bounding box* yang sesuai dengan posisi objek sebenarnya. Hasil tersebut menunjukkan bahwa model tidak hanya mampu melakukan klasifikasi dengan baik, tetapi juga memiliki kemampuan deteksi multi-objek yang akurat pada kelas *normal*.


3.5 Pembahasan

Hasil penelitian ini menunjukkan bahwa model YOLOv11 mampu memberikan performa yang tinggi dalam mendeteksi kecacatan fisik pada cangkang telur. Berdasarkan hasil evaluasi, model memperoleh nilai *precision*, *recall*, *F1-Score*, *mAP50*, dan *mAP50-95* yang menunjukkan kemampuan deteksi dan klasifikasi yang baik pada kedua kategori telur.

Hasil yang diperoleh sejalan dengan penelitian Ong dkk. (2026) yang menggunakan pendekatan *Attention-Guided Convolutional Neural Network* untuk mendeteksi kecacatan telur dan mencapai akurasi sebesar 98,47%. Selain itu, penelitian Huang dkk. (2023) yang menerapkan YOLOv5 pada deteksi kerusakan telur memperoleh akurasi sebesar 96,4%. Meskipun menggunakan pendekatan yang berbeda, hasil penelitian ini menunjukkan bahwa model YOLOv11 mampu menghasilkan performa yang tinggi dan sejalan dengan berbagai penelitian terdahulu pada bidang deteksi kecacatan telur.



Gambar 4. Perbandingan *ground truth* dan hasil prediksi YOLOv11 pada kelas *damaged*.



Gambar 5. Hasil deteksi beberapa telur normal menggunakan YOLOv1

Temuan ini menunjukkan bahwa YOLOv11 memiliki potensi untuk diterapkan pada proses inspeksi kualitas telur secara otomatis. Kemampuan model dalam mendeteksi telur normal maupun telur cacat pada berbagai kondisi citra menunjukkan bahwa pendekatan berbasis deep learning dapat mendukung proses quality assurance secara lebih efisien dan konsisten dibandingkan proses inspeksi manual.

4. KESIMPULAN

Penelitian ini berhasil mengevaluasi kinerja arsitektur ringan YOLOv11n dalam mendeteksi kecacatan fisik pada cangkang telur menggunakan dataset Damaged dan Normal. Berdasarkan pengujian dengan skema 5-Fold Cross Validation, model memperoleh performa yang baik dengan nilai *precision*, *recall*, *F1-Score*, *mAP50*, dan *mAP50-95* yang seluruhnya berada di atas 0,90. Hasil visualisasi deteksi juga menunjukkan bahwa model mampu melakukan lokalisasi objek telur normal maupun telur cacat dengan baik. Adapun kontribusi krusial dari penelitian ini bagi ranah keilmuan visi komputer adalah pembuktian empiris bahwa integrasi algoritma pendeteksi mutakhir YOLOv11n dengan skema augmentasi spasial mampu memberikan kerangka penyelesaian yang tangguh untuk mengatasi anomali ketimpangan kelas pada dataset skala kecil. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada jumlah dan variasi dataset, serta belum mencakup pengujian kecepatan inferensi seperti *latency* atau *frames per second* (FPS) pada perangkat nyata. Oleh karena itu, YOLOv11n dapat diposisikan sebagai model yang berpotensi mendukung inspeksi visual kualitas telur, sedangkan penelitian selanjutnya disarankan menggunakan dataset yang lebih beragam, pengujian pada kondisi industri nyata, serta evaluasi kecepatan inferensi.

REFERENCES

- [1] M. Turkoglu, "Defective egg detection based on deep features and Bidirectional Long-Short-Term-Memory," *Comput. Electron. Agric.*, vol. 185, Jun 2021, doi: 10.1016/j.compag.2021.106152.
- [2] Y. Fang dkk., "Research on the detecting method for cracks on perforated embryo eggs based on acoustic responses," *Poult. Sci.*, vol. 104, no. 11, Nov 2025, doi: 10.1016/j.psj.2025.105765.
- [3] V. M. Nakaguchi dan T. Ahamed, "Fast and Non-Destructive Quail Egg Freshness Assessment Using a Thermal Camera and Deep Learning-Based Air Cell Detection Algorithms for the Revalidation of the Expiration Date of Eggs," *Sensors*, vol. 22, no. 20, hlm. 7703, 2022.
- [4] R. Ranjan, "YOLO in precision aquaculture: A decadal bibliometric and systematic review of applications, architectural adaptations, and deployment challenges," *J. Agric. Food Res.*, vol. 28, hlm. 102982, 2026.
- [5] P. Ong, C. K. Sia, dan C. K. Cheong, "Attention Guided Convolutional Neural Networks for Accurate Egg Defect Detection in Food Quality Assessment," *Food Bioproc. Tech.*, vol. 19, hlm. 203, 2026.
- [6] I. Baek dkk., "Explainable deep learning framework for fecal contamination detection on chicken eggshells via portable fluorescence imaging under ambient light," *Poult. Sci.*, vol. 105, hlm. 106868, 2026.
- [7] S. Li, M. Tang, S. Tong, dan K. Sun, "Research on image recognition of cracked eggs based on convolutional neural network model," *Food and Machinery*, vol. 39, no. 11, hlm. 18–22, 2023.
- [8] J. Chen, H. Fu, C. Lin, X. Liu, L. Wang, dan Y. Lin, "YOLOPears, a novel benchmark of YOLO object detectors for multi-class pear surface defect detection in quality grading systems," *Front. Plant Sci.*, vol. 16, hlm. 1483824, 2025.
- [9] J. Liu, J. Zhang, Z. Ma, E. Li, dan J. Yuan, "An Online Quality Detection Algorithm for Cocoon Clusters Based on CD-YOLO," *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3522310.
- [10] L. Fu, L. Li, G. Zhang, dan Z. Jiang, "An Integrated and Robust Vision System for Internal and External Thread Defect Detection with Adversarial Defense," *Sensors*, 2024.
- [11] Y. Huang dkk., "Damage Detection of Unwashed Eggs through Video and Deep Learning," *Foods*, vol. 12, no. 11, hlm. 2179, 2023.
- [12] G. Deng, J. Guo, dan Q. Li, "NONDESTRUCTIVE TESTING OF DUCK EGGS DURING INCUBATION USING YOLO-LITE," *Ukrainian Journal of Physical Optics*, vol. 25, no. 2, 2024.
- [13] F. Chen, M. Deng, H. Gao, X. Yang, dan D. Zhang, "NHD-YOLO: Improved YOLOv8 using optimized neck and head for product surface defect detection with data augmentation," *IET Image Process.*, 2024, doi: 10.1049/ipr2.13073.
- [14] K. Luo dkk., "An optimized YOLOv8n based model for real time defect detection in taro strip production," *Sci. Rep.*, vol. 15, hlm. 44685, 2025, doi: 10.1038/s41598-025-28216-x.
- [15] J. Liu, X. Zhu, X. Zhou, S. Qian, dan J. Yu, "Defect Detection for Metal Base of TO-Can Packaged Laser Diode Based on

- Improved YOLO Algorithm,” *Electronics (Basel)*, vol. 11, no. 10, hlm. 1561, 2022, doi: 10.3390/electronics11101561.
- [16] Z. Yin, H. Li, S. Chen, K. Luo, R. Xiang, dan H. Shen, “Real-time steel core defect detection using enhanced lightweight object detection algorithm with data augmentation,” *Computational Materials Today*, vol. 10, hlm. 100056, 2026.
- [17] C. Zhao, X. Liang, H. Yu, H. Wang, S. Fan, dan B. Li, “Automatic Identification and Counting Method of Caged Hens and Eggs Based on Improved YOLO v7,” *Transactions of the Chinese Society for Agricultural Machinery*, vol. 54, no. 7, 2023, doi: 10.6041/j.issn.1000-1298.2023.07.030.
- [18] S. Liu, Z. Wang, J. Yuan, dan Z. Wei, “Lightweight Quail Egg Crack Online Non-destructive Testing System Based on Improved YOLO 11,” *Transactions of the Chinese Society for Agricultural Machinery*, vol. 57, no. 10, 2026, doi: 10.6041/j.issn.1000-1298.2026.10.039.
- [19] D. V. Nguyen, Q.-B. Nguyen, H.-D. P. Le, dan N. H. Tran, “Smart Food Manufacturing: Integrating Deep Learning Models for Enhancing Efficiency in Broken Egg Detection,” dalam *Computational Intelligence in Engineering Science*, Springer Nature Switzerland, 2026, hlm. 98–110.
- [20] A. Miski, “Benchmarking Lightweight YOLO Architectures for Real-Time Eggshell Defect Detection Toward Augmented-Reality Inspection in Poultry Supply Chains,” *IEEE Access*, vol. 14, hlm. 75918–75932, 2026, doi: 10.1109/ACCESS.2026.3693963.