



Multi-Hierarchical Machine Learning Approach for Edible Bird's Nest Grading Based on Shape Detection and Color Classification

Pendekatan Multi-Hirarki untuk Grading Sarang Burung Walet Berdasarkan Deteksi Bentuk dan Klasifikasi Warna

Reinhard Alfaries Saemani^{1*}, Danny Manongga², Hendry³

^{1,2,3}Magister Sistem Informasi, Fakultas Teknologi Informasi,
Universitas Kristen Satya Wacana, Salatiga, Indonesia

E-Mail: ¹972022005@student.uksw.edu, ²danny.manongga@uksw.edu, ³hendry@uksw.edu

Received Jan 20th 2026; Revised Mar 04th 2026; Accepted Mar 17th 2026; Available Online Apr 18th 2026

Corresponding Author: Reinhard Alfaries Saemani

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Edible Bird's Nests (EBN) are high-value commodities whose grading is still largely manual, making them prone to subjectivity and inconsistency, particularly in assessing shape and color. This study aims to develop an objective, consistent grading system for EBN at the raw-material stage using a multi-hierarchical machine-learning approach. The system consists of two levels: shape detection using YOLOv8 to classify EBN into three main categories (bowl, oval, triangular), and color analysis of cropped nest regions through HSV-based segmentation, followed by classification in the CIELAB color space. The model was trained on 840 images (3,360 objects) and tested on 120 images (480 objects), with quantitative evaluation of detection and classification performance. Experimental results show that YOLOv8 achieved a mAP@0.5 of 99.5%, with very high precision and recall across all shape categories, while color analysis produced quantitative distributions of white, yellow, and intense yellow without inter-class overlap. This approach integrates real-time shape detection using YOLOv8 with perceptually uniform CIELAB color classification, yielding an accurate, consistent, and industry-applicable EBN grading system, and providing a more comprehensive integrated method compared to previous studies that focused solely on either shape or color.

Keywords: CIELAB, Edible Bird's Nests, Grade, Swiftlet Nest, YOLOv8

Abstrak

Sarang burung walet (SBW) merupakan komoditas bernilai ekonomi tinggi yang grading-nya masih banyak dilakukan secara manual sehingga rentan terhadap subjektivitas dan inkonsistensi, khususnya pada penilaian bentuk dan warna. Penelitian ini bertujuan mengembangkan sistem grading SBW yang objektif dan konsisten pada tahap bahan mentah melalui pendekatan multi-hirarki berbasis *machine learning*. Sistem terdiri dari dua level: deteksi bentuk menggunakan YOLOv8 untuk mengklasifikasikan tiga kategori utama (mangkuk, oval, segitiga), dan analisis warna pada area sarang hasil *cropping* melalui segmentasi HSV lalu klasifikasi di ruang warna CIELAB. Model dilatih menggunakan 840 citra (3360 objek) dan diuji pada 120 citra (480 objek), dengan evaluasi performa deteksi dan klasifikasi secara kuantitatif. Hasil eksperimen menunjukkan YOLOv8 mencapai mAP@0,5 sebesar 99,5% dengan presisi dan *recall* sangat tinggi pada semua kelas bentuk, sedangkan analisis warna menghasilkan distribusi kuantitatif warna putih, kuning, dan kuning sekali tanpa tumpang tindih antar kelas. Pendekatan ini mengintegrasikan deteksi bentuk *real-time* berbasis YOLOv8 dengan klasifikasi warna *perceptually uniform* CIELAB, menghasilkan sistem grading SBW yang akurat, konsisten, dan aplikatif di industri, sekaligus menghadirkan metode terintegrasi yang lebih komprehensif dibandingkan penelitian sebelumnya yang hanya menekankan salah satu aspek, bentuk atau warna.

Kata Kunci: CIELAB, Grade, Sarang Burung Walet, Sarang Walet, YOLOv8

1. PENDAHULUAN

Sarang burung walet (SBW) merupakan komoditas bernilai tinggi di Asia, khususnya di Indonesia, Malaysia, Thailand, dan Tiongkok. Indonesia merupakan pemasok SBW terbesar dunia, dengan produksi mencapai 80% dari total produksi global, sementara negara lain berkontribusi 10–20% [1], [2]. Permintaan



global terhadap SBW terus meningkat karena nilai ekonomisnya yang tinggi, sehingga dimanfaatkan dalam industri pangan fungsional, kesehatan, dan kosmetik [3], [4], [5].

PT Waleta Asia Jaya adalah perusahaan pengolahan SBW di Jawa Tengah yang menangani proses dari bahan mentah hingga produk siap ekspor. Proses ini melibatkan beberapa departemen: bahan mentah, produksi, bahan jadi, dan *packing*. Departemen bahan mentah melakukan verifikasi data melalui penimbangan, pencatatan berat, dan daerah asal. Selanjutnya, SBW diklasifikasikan berdasarkan kategori bentuk, bulu, dan warna (Tabel 1). Departemen produksi menangani perendaman, pencucian, pembersihan, pencabutan bulu, dan pengeringan. Departemen bahan jadi melakukan grading ulang berdasarkan grading bahan jadi, pencatatan, dan penyimpanan, sedangkan departemen *packing* mengemas produk untuk ekspor [6].

Tabel 1. Kategori Klasifikasi SBW

No	Kategori	Jenis
1	Bentuk	Mangkok
		Oval
		Segitiga
2	Bulu	Bulu Ringan Sekali/Bulu Ringan
		Bulu Sedang
		Bulu Berat
3	Warna	Warna 1 (Putih)
		Warna 2 (Kuning)
		Warna 3 (Kuning Sekali)

Untuk meningkatkan kapasitas ekspor, diperlukan proses pengolahan yang cepat dan konsisten. Tantangan utama terletak pada departemen bahan mentah, khususnya grading manual yang memakan waktu lama dan rentan terhadap subjektivitas evaluator. Meskipun conveyor digunakan untuk deteksi intensitas bulu, penilaian bentuk dan warna masih bergantung pada penilaian visual, yang dapat menyebabkan inkonsistensi dan kesalahan [7]. Konsistensi grading sarang burung walet sangat penting untuk menjaga stabilitas harga dan kepercayaan pasar ekspor, sehingga pengembangan metode grading otomatis berbasis *machine learning* menjadi sangat krusial [8]. Oleh karena itu, deteksi otomatis berbasis *machine learning* diperlukan untuk objektivitas.

Kualitas fisik sarang burung walet memiliki keterkaitan langsung dengan harga jual dan daya saing produk di pasar. Penelitian Ansari dan Rifani (2024) menunjukkan bahwa atribut kualitas seperti kebersihan, tekstur, bentuk, dan warna merupakan faktor utama dalam penentuan harga sarang burung walet di tingkat produsen. Sarang dengan bentuk utuh dan warna cerah dinilai memiliki kualitas lebih tinggi dan memperoleh harga jual yang lebih baik. Temuan tersebut menegaskan bahwa proses penilaian bentuk dan warna bukan sekadar aspek visual, tetapi berimplikasi langsung terhadap nilai ekonomi produk [8].

Namun, penilaian kualitas SBW pada praktiknya masih sangat bergantung pada persepsi subjektif manusia, baik di tingkat peternak maupun industri pengolahan. Perbedaan persepsi dalam menilai atribut fisik SBW berpotensi menimbulkan inkonsistensi grading yang berdampak pada fluktuasi harga dan ketidakstabilan kualitas produk. Dalam konteks industri berorientasi ekspor, konsistensi kualitas menjadi faktor krusial untuk menjaga stabilitas harga dan kepercayaan pasar. Oleh karena itu, dibutuhkan pendekatan penilaian kualitas yang objektif, terukur, dan konsisten sejak tahap bahan mentah.

Penelitian mengenai SBW selama ini lebih banyak berfokus pada aspek kimia, keamanan pangan, kandungan nutrisi, dan produk yang berasal dari SBW [9], [10], [11], [12]. Kajian identifikasi bentuk dan warna berbasis citra digital masih terbatas, padahal keduanya memengaruhi nilai jual [13], [14]. Penelitian Indrajaya et al. (2022) menggunakan SSD MobileNet V2 FPNLite untuk klasifikasi bentuk dengan akurasi *mAP* 61%, namun belum mencakup warna [15]. Kesenjangan ini membuka peluang pengembangan model yang lebih akurat.

Beberapa studi terkini mendukung adopsi metode grading berbasis *computer vision* dan *deep learning* untuk produk organik maupun pangan, sehingga relevan untuk kasus SBW. Grading buah tropis dan produk pertanian menggunakan *CNN* ringan seperti *MobileNetV2* dan variannya terbukti mencapai akurasi tinggi dengan parameter yang efisien, menunjukkan potensi integrasi *computer vision* dalam penilaian kualitas visual [16], [17]. Model deteksi objek terbaru seperti *YOLOv8* juga telah diterapkan pada objek organik, dengan kinerja *real-time* dan kemampuan menangani variasi bentuk serta ukuran secara *robust*, yang penting untuk klasifikasi bentuk SBW [18], [19]. Di sisi lain, klasifikasi warna di industri pangan menggunakan ruang warna *perceptually uniform* seperti CIELAB terbukti mampu menangkap perbedaan warna yang dekat dengan persepsi manusia, bahkan di bawah pencahayaan variabel, sehingga mendukung segmentasi warna yang konsisten dalam grading produk [20], [21]. Temuan ini mengindikasikan bahwa kombinasi deteksi bentuk *real-time* berbasis *YOLOv8* dengan klasifikasi warna yang *perceptually uniform* dapat meningkatkan akurasi dan konsistensi grading objek organik seperti sarang burung walet.

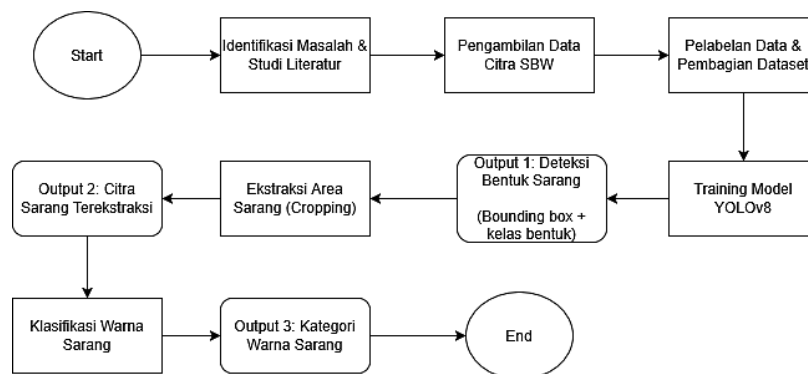
Penelitian ini mengusulkan multi hirarki prediksi grade SBW menggunakan *machine learning*. Pada level bentuk, *YOLOv8* digunakan untuk deteksi dan klasifikasi menjadi mangkok, oval, dan segitiga. *YOLOv8* efektif dalam mendeteksi objek dengan variasi bentuk dan ukuran [22], [23]. Dibanding metode lain, *YOLOv8* dipilih karena kemampuannya mendeteksi objek secara *real-time* dengan akurasi tinggi, efisien dalam pemrosesan multi-objek, dan *robust* terhadap variasi bentuk dan ukuran SBW. Dalam proses klasifikasi warna, ruang warna HSV digunakan untuk segmentasi dan penghilangan elemen bulu melalui analisis komponen saturasi dan value, yang sensitif terhadap variasi pencahayaan dan perubahan warna halus, mirip dengan penerapannya dalam deteksi titrasi redox atau kontur visual di mana *hue* (H) dan *saturation* (S) secara kolektif menangkap perubahan kromatisitas dengan sensitivitas tinggi [24]. Sementara itu, ruang warna CIELAB diterapkan untuk klasifikasi warna berdasarkan komponen a^* dan b^* , yang bersifat *perceptually uniform* sehingga mendekati persepsi manusia terhadap perbedaan warna [25], [26].

YOLOv8 menawarkan kelebihan seperti kecepatan *real-time* (hingga 65 FPS pada *edge hardware* seperti Jetson Orin NX dengan kuantisasi INT8) dan akurasi tinggi untuk deteksi objek variatif bentuk ($mAP@0.5$ hingga 37.3–80.9% pada dataset COCO tergantung varian seperti *YOLOv8n*) [27], menjadikannya unggul untuk klasifikasi bentuk SBW seperti mangkok, oval, dan segitiga. Namun, kekurangannya mencakup sensitivitas rendah terhadap variasi warna dan tekstur halus di bawah pencahayaan tidak merata, dengan penurunan akurasi signifikan (rata-rata hingga 30% pada kondisi *outdoor*/lapangan untuk objek organik seperti buah karena gangguan latar belakang, warna serupa, dan lighting variabel), disebabkan ketergantungan pada RGB yang *non-uniform* [28]. Demikian pula, ruang warna CIELAB unggul dalam *uniformity persepsi* (ΔE mendekati perbedaan mata manusia) dan *robust* terhadap iluminasi untuk klasifikasi warna (efektif memisahkan kategori warna pada grading buah/tanaman dengan threshold presisi tinggi via clustering) [29], tetapi lemah dalam segmentasi *real-time* tanpa integrasi deep learning, rentan *noise* dari bayangan/bulu/latar belakang, serta komputasi intensif (memerlukan pemrosesan terpisah *luminance-chrominance* yang menambah *latency* pada aplikasi industri cepat). Kesenjangan ini—kurangnya model hibrida yang menggabungkan deteksi bentuk cepat *YOLOv8* dengan klasifikasi warna *perceptually uniform* CIELAB, terutama untuk objek organik bertekstur seperti SBW—membuka peluang pengembangan sistem multi-hirarki untuk grading SBW yang akurat, konsisten, dan *real-time* di lingkungan industri [30].

Penelitian ini berkontribusi dalam menyediakan sistem grading berbasis *machine learning* sebagai alat bantu objektif dan konsisten bagi industri pengolahan sarang burung walet pada tahap bahan mentah, melalui deteksi bentuk dan klasifikasi warna. Sistem ini berpotensi mengurangi subjektivitas evaluator manusia, mempercepat proses grading, serta mendukung standarisasi kualitas produk yang berdampak pada kestabilan harga dan pemenuhan standar pasar ekspor.

2. METODOLOGI PENELITIAN

Dalam melakukan penelitian ini, dilakukan proses pelatihan menggunakan data berupa citra digital. Proses penelitian ini terdiri dari beberapa tahapan, lihat Gambar 1.



Gambar 1. Diagram Alir

2.1. Perencanaan Pelaksanaan Penelitian

Perencanaan merupakan tahap awal yang dilakukan dalam penelitian ini, meliputi identifikasi permasalahan yang dihadapi, studi literatur, dan analisis untuk menyelesaikan permasalahan tersebut.

2.2. Pengambilan Data

Data yang diambil adalah data primer atau data asli yang diambil dari hasil pengambilan gambar conveyor yang menangani deteksi intensitas bulu. Data yang diperoleh sebanyak 1200 gambar dengan pembagian 400 gambar bentuk mangkok, 400 gambar bentuk oval, dan 400 gambar bentuk segitiga dan setiap gambar mempunyai 4 sisi yaitu depan, belakang, kiri, kanan.

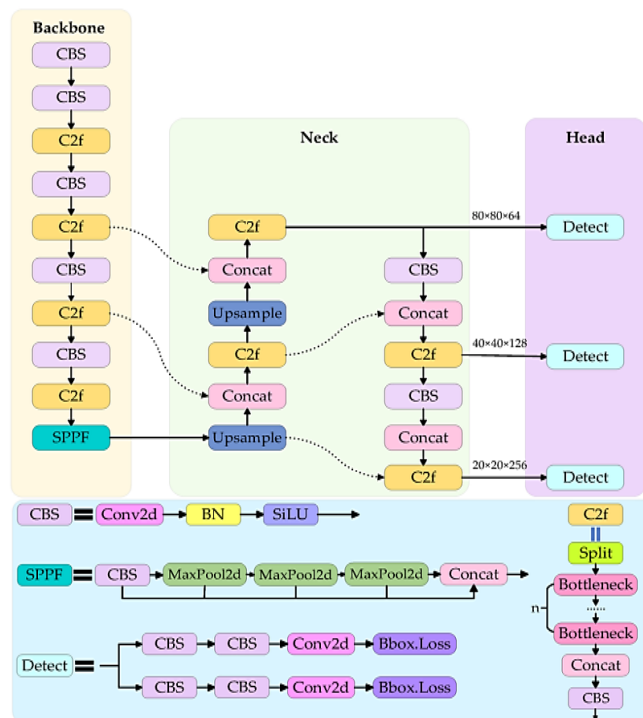
2.3. Pelabelan Data dan Pembagian Dataset

Proses pelabelan ini menggunakan platform Roboflow yang mencakup pemberian anotasi *bouding box* pada area sarang burung walet. Dataset dibagi menjadi 70% untuk data *training* (840 gambar), 20% untuk data *validation* (240 gambar), dan 10% untuk data *testing* (120 gambar). Setiap gambar memiliki 4 sisi (depan, belakang, kiri, kanan) dan setiap sisi diberi label *bouding box* sesuai kelas bentuk: Mangkok, Oval, dan Segitiga.

2.4. Pelatihan Model dan Deteksi Bentuk Sarang

Setelah pelabelan data, selanjutnya dataset tersebut akan digunakan untuk melatih model *YOLOv8*. Proses pelatihan bertujuan agar model mampu mengenali dan membedakan ketiga bentuk sarang. Hasil dari tahap ini adalah model terbaik (*best model*) yang dapat menghasilkan *bouding box* prediksi pada setiap citra, sehingga posisi sarang dapat diidentifikasi dengan akurat.

YOLOv8 merupakan model deteksi objek satu tahap (*one-stage detector*) yang tersusun atas tiga komponen utama, yaitu *backbone*, *neck*, dan *head*, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Model *YOLOv8*[31]

Bagian *backbone* berfungsi untuk mengekstraksi fitur dari citra masukan menggunakan kombinasi *convolutional layer* dan modul C2f yang dirancang untuk meningkatkan efisiensi serta kemampuan representasi fitur. Fitur-fitur yang dihasilkan pada berbagai skala kemudian diteruskan ke bagian *neck*, yang menggunakan mekanisme *Path Aggregation Network – Feature Pyramid Network* (PAN-FPN) untuk menggabungkan informasi fitur dari berbagai tingkat resolusi. Proses ini bertujuan untuk meningkatkan kemampuan model dalam mendeteksi objek dengan ukuran yang bervariasi. Pelatihan model *YOLOv8n* dilakukan menggunakan library Ultralytics *YOLOv8* dengan konfigurasi: *batch size* 16, ukuran input 640x640 piksel, *optimizer* SGD, *learning rate* awal 0.01, 100 epoch, dan *early stopping* dengan *patience* 20. Pelatihan dilakukan pada GPU *device* 0, dengan project disimpan pada folder ‘sarang-walet’ [31]. Evaluasi performa model dilakukan menggunakan metrik *mAP@0.5*, *Precision*, dan *Recall* pada dataset *validation* untuk memastikan kemampuan generalisasi model.

Selanjutnya, bagian *YOLO head* berfungsi sebagai komponen prediksi yang melakukan regresi *bouding box* dan klasifikasi objek secara terpisah (*decoupled head*). *Head* ini menghasilkan informasi posisi objek, ukuran *bouding box*, serta kelas bentuk sarang burung walet pada setiap citra.

YOLOv8 tersedia dalam beberapa varian, yaitu *YOLOv8n*, *YOLOv8s*, *YOLOv8m*, *YOLOv8l*, dan *YOLOv8x*, yang memiliki perbedaan pada kedalaman dan lebar jaringan. Dalam penelitian ini digunakan varian *YOLOv8n* karena memiliki kompleksitas komputasi yang lebih rendah, kecepatan inferensi yang tinggi, serta sesuai untuk kebutuhan deteksi secara *real-time* pada tahap bahan mentah sarang burung walet.

Pada penelitian ini, arsitektur *YOLOv8* digunakan tanpa melakukan perubahan struktur jaringan. Optimasi difokuskan pada proses pelatihan model dan penyesuaian parameter agar diperoleh performa deteksi yang optimal sesuai dengan karakteristik data sarang burung walet.

2.5. Ekstraksi Area Sarang (*Cropping*)

Tahap ini dilakukan setelah model *YOLOv8* menghasilkan *bounding box* pada setiap citra. *Bounding box* tersebut digunakan untuk memotong area sarang sehingga hanya bagian yang relevan yang dianalisis pada proses klasifikasi warna. Proses *cropping* dilakukan melalui langkah-langkah berikut.

1. Mengambil koordinat *bounding box* yang dihasilkan oleh model *YOLOv8*.
2. Melakukan pemotongan (*cropping*) area sarang berdasarkan koordinat tersebut.
3. Menyimpan hasil *cropping* sebagai input untuk tahap klasifikasi warna.

2.6. Klasifikasi Warna Sarang

Tahap ini menggunakan hasil *cropping* dari proses sebelumnya sebagai input utama. Analisis warna dilakukan dengan mengekstraksi informasi warna dari area sarang, kemudian mengelompokkan citra ke dalam tiga kategori warna utama. Keluaran tahap ini adalah penentuan kelas warna akhir untuk setiap sarang berdasarkan hasil analisis area yang telah diekstraksi.

Ruang warna HSV digunakan untuk segmentasi area sarang karena komponen H dan S sensitif terhadap saturasi dan value, memudahkan penghilangan elemen bulu dan background [24]. Ruang warna CIELAB dipilih karena *perceptually uniform* mendekati persepsi manusia dan robust terhadap pencahayaan variabel, sehingga klasifikasi warna menjadi konsisten pada kondisi pencahayaan yang berbeda [25], [26]. Pendekatan ini sesuai dengan praktik grading warna pada produk organik dan pangan yang memerlukan presisi tinggi [29].

3. HASIL DAN PEMBAHASAN

3.1. Hasil

3.1.1 Deteksi Bentuk

Pada tahap pertama penelitian ini, dilakukan deteksi bentuk sarang burung walet (SBW) menggunakan metode *YOLOv8*. Evaluasi performa model dilakukan menggunakan metrik *mean Average Precision (mAP)* yang diperoleh dari nilai *Average Precision (AP)* pada setiap kelas. Pengujian dilakukan menggunakan 120 citra data uji, yang terdiri dari 40 citra kelas mangkok, 40 citra kelas oval, dan 40 citra kelas segitiga. Setiap citra mengandung empat objek sarang, sehingga total objek yang dievaluasi berjumlah 480 objek.

Evaluasi ini bertujuan untuk menilai kemampuan model *YOLOv8* dalam mendeteksi dan mengklasifikasikan bentuk sarang burung walet secara akurat sebelum dilanjutkan ke tahap prediksi warna. Dalam sistem deteksi objek, unit evaluasi utama berada pada level objek, bukan hanya pada level citra, karena metrik seperti *precision*, *recall*, dan *mAP* dihitung berdasarkan jumlah objek yang terdeteksi secara benar maupun salah. Oleh karena itu, penggunaan jumlah objek uji yang lebih besar dibandingkan jumlah citra memungkinkan evaluasi performa model yang lebih representatif dan stabil. Selain itu, keberadaan beberapa objek dalam satu citra mencerminkan kondisi operasional nyata pada proses grading bahan mentah berbasis conveyor, di mana objek dapat muncul secara bersamaan dengan variasi posisi dan orientasi.

Kinerja model dievaluasi menggunakan metrik *mAP* dengan ambang batas *Intersection over Union (IoU)* sebesar 0,5, yang merupakan nilai standar yang umum digunakan dalam evaluasi sistem deteksi objek. Ambang batas ini dianggap cukup untuk menilai ketepatan lokalisasi dan klasifikasi objek secara fungsional, khususnya pada aplikasi industri yang tidak menuntut presisi piksel yang sangat tinggi, tetapi menekankan pada keandalan deteksi objek secara konsisten.

Data uji terdiri dari tiga kelas bentuk, yaitu mangkok, oval, dan segitiga, dengan distribusi kelas yang seimbang. Distribusi data yang seimbang ini bertujuan untuk meminimalkan bias evaluasi terhadap kelas tertentu serta memastikan bahwa nilai *mAP* yang diperoleh mencerminkan kemampuan model secara adil pada setiap kelas bentuk. Secara teoretis, dataset uji yang seimbang menghasilkan estimasi performa yang lebih objektif, terutama karena *mAP* merupakan rata-rata nilai AP dari setiap kelas. Dengan total 480 objek uji, jumlah tersebut dinilai memadai untuk mengukur stabilitas dan konsistensi performa model *YOLOv8* dalam mendeteksi variasi bentuk SBW.

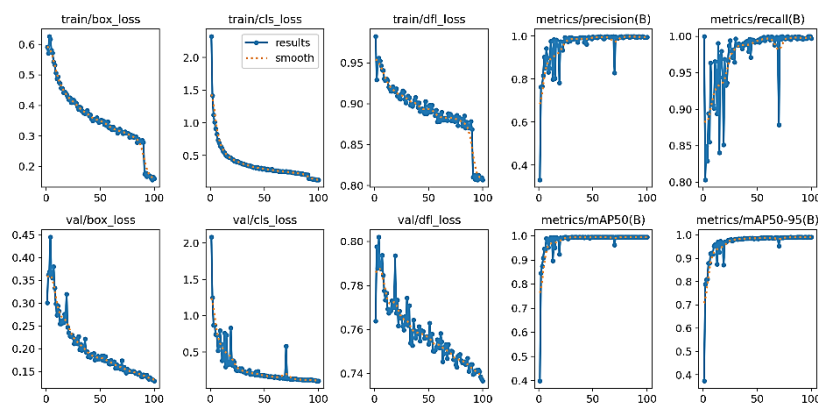
Selama proses pelatihan model deteksi bentuk, dilakukan pemantauan terhadap grafik *training* yang meliputi perubahan nilai loss dan metrik evaluasi *mAP* seiring bertambahnya epoch. Model dilatih dengan jumlah maksimum 100 *epoch* dan mekanisme *early stopping* dengan nilai *patience* sebesar 20. Berdasarkan grafik *training*, terlihat bahwa nilai *loss* (*box loss* dan *classification loss*) menurun secara signifikan pada fase awal pelatihan dan kemudian mencapai kondisi stabil, yang mengindikasikan proses konvergensi model berjalan dengan baik dapat dilihat pada Gambar 3.

Seiring dengan penurunan nilai *loss*, nilai *mAP@0.5* pada data validasi mengalami peningkatan yang konsisten hingga mendekati nilai maksimum, kemudian cenderung stabil tanpa fluktuasi tajam. Sejalan

dengan Dolhopolov et al. (2024) yang melaporkan pola serupa pada pelatihan *YOLOv8* dengan *patience 20 epoch* [32]. Penggunaan *early stopping* efektif mencegah *overfitting*, sebagaimana dibuktikan dengan performa stabil pada data validasi. Mekanisme *early stopping* berperan dalam menghentikan proses pelatihan ketika tidak terjadi peningkatan performa validasi dalam sejumlah *epoch* berturut-turut, sehingga pelatihan dapat dihentikan pada kondisi optimal tanpa perlu menyelesaikan seluruh *epoch* maksimum.

Pola konvergensi yang stabil pada grafik *training* ini memperkuat hasil evaluasi kuantitatif yang diperoleh pada data uji, serta menunjukkan bahwa arsitektur *YOLOv8n* yang digunakan memiliki kemampuan pembelajaran yang efisien dan andal dalam mendeteksi serta mengklasifikasikan bentuk sarang burung walet dengan variasi posisi dan orientasi objek, sebagaimana dilaporkan pada aplikasi deteksi objek kompleks lainnya [33].

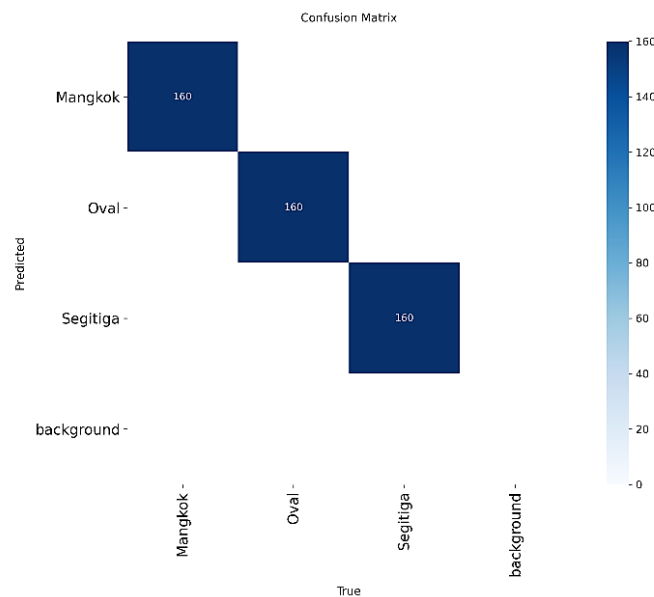
Hasil evaluasi menunjukkan bahwa model *YOLOv8* mampu mendeteksi seluruh objek pada data uji dengan tingkat presisi dan *recall* yang sangat tinggi. *Confusion matrix* yang dihasilkan tidak menunjukkan adanya kesalahan klasifikasi antar kelas yang terlihat pada Gambar 4, yang mengindikasikan bahwa model mampu membedakan ketiga bentuk sarang secara konsisten. Nilai presisi yang mendekati 1 menunjukkan rendahnya kesalahan deteksi objek yang tidak relevan, sedangkan nilai *recall* sebesar 1 menunjukkan bahwa seluruh objek sarang pada data uji berhasil terdeteksi oleh model seperti yang terlihat pada Tabel 2.



Gambar 3. Grafik Training Model

Tabel 2. Confusion matrix


Kelas	Gambar	Objek	Presisi	Recall	mAP50
Mangkok	40	160	0.999	1	0.995
Oval	40	160	1.000	1	0.995
Segitiga	40	160	0.999	1	0.995
Semua	120	480	1.000	1	0.995




Gambar 4. Confusion matrix

Nilai presisi yang mendekati 1 menunjukkan bahwa model hampir tidak menghasilkan deteksi salah, sehingga setiap sarang yang terdeteksi sesuai dengan kelasnya. Nilai 1 pada *recall* menunjukkan bahwa seluruh objek sarang berhasil terdeteksi, sehingga tidak ada sarang yang terlewat, yang penting untuk aplikasi grading industri. Nilai AP tinggi pada setiap kelas dan *mAP* sebesar 0,995 menunjukkan performa konsisten di seluruh kelas bentuk, menegaskan bahwa model tidak bias terhadap salah satu kelas dapat dilihat pada kurva *Precision-Recall* seperti pada Gambar 5. Secara ilmiah, hal ini menandakan bahwa model *YOLOv8n* tidak hanya menghasilkan angka tinggi, tetapi benar-benar mampu mengekstraksi dan membedakan fitur bentuk sarang secara efektif. Oleh karena itu penelitian ini tidak sekadar menampilkan hasil, tetapi memberikan analisis yang menjelaskan kemampuan model dalam konteks operasional nyata.


Dengan rata-rata nilai AP di ketiga kelas, *mAP@0.5* sebesar 0,995 (99,5%) berhasil dicapai. Gambar 6, 7, dan 8 menyajikan hasil deteksi representatif untuk setiap kelas, dengan skor kepercayaan (*Confidence Score*) melebihi 0,95 (95%).



Gambar 5. Kurva *Precision-Recall*




Gambar 6. Hasil Deteksi Bentuk Mangkok




Gambar 7. Hasil Deteksi Bentuk Oval

Visualisasi deteksi pada Gambar 9 menunjukkan bahwa sebagian kecil pergeseran antara *bounding box Ground Truth* dan prediksi tidak menurunkan *mAP* secara signifikan karena IoU tetap di atas 0,5. Pergeseran kecil ini menyebabkan IoU sedikit lebih rendah dari 1, sehingga *mAP* sedikit kurang sempurna menjadi 0,995. Pergeseran yang lebih besar atau objek dengan kontur tipis/putus dapat menyebabkan IoU <

threshold, yang sedikit menurunkan AP pada kelas tersebut. Hal ini menunjukkan model sangat *robust* terhadap variasi posisi dan orientasi objek, tetapi tetap memiliki sensitivitas terhadap kondisi pencahayaan ekstrem, objek dengan kontur tipis, atau tekstur yang sangat halus. Strategi augmentasi citra, penyesuaian pencahayaan, dan penambahan data pelatihan dapat diterapkan untuk lebih meningkatkan *robustness* model.



Gambar 8. Hasil Deteksi Bentuk Segitiga



Gambar 9. Perbandingan *Ground Truth* dan Prediksi *YOLOv8* pada SBW

Pada Tabel 3, *YOLOv8n* mencapai *mAP@0,5* sebesar 99,5%, jauh lebih tinggi dibanding *MobileNet V2 FPNLite SSD* yang hanya 61,91%. Nilai AP pada *YOLOv8n* hampir seragam di seluruh kelas bentuk sarang mendekati 1, menunjukkan kestabilan model dalam mendeteksi dan mengklasifikasikan bentuk sarang dengan variasi posisi dan orientasi. Peningkatan performa ini menunjukkan bahwa arsitektur *YOLOv8n* mampu mengekstraksi fitur bentuk sarang secara lebih efektif dibanding arsitektur *MobileNet V2 FPNLite SSD*, yang menunjukkan performa lebih rendah terutama pada kelas oval akibat beberapa prediksi salah kelas dan sensitivitas terhadap bentuk sulit atau jumlah data terbatas. Hasil ini juga menunjukkan bahwa *YOLOv8n* lebih *robust* terhadap variasi posisi, orientasi, dan kontur objek. Untuk implementasi industri, perhatian terhadap kondisi pencahayaan, variasi tekstur, dan kemungkinan augmentasi citra tetap diperlukan guna memastikan keandalan sistem grading berbasis citra digital pada industri sarang burung walet.

Tabel 3. Perbandingan performa deteksi bentuk sarang

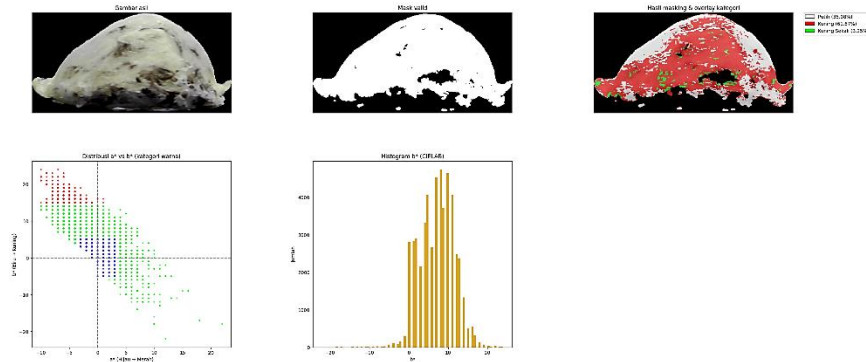
Metode	Kelas	Objek	AP	mAP50
YOLOv8n	Mangkok	160	0.995	99,5%
	Oval	160	0.995	
	Segitiga	160	0.995	
MobileNet V2	Mangkok	24	75.08	61,91%
	Oval	24	33.57	
FPNLite SSD	Segitiga	24	77.07	

3.1.2 Klasifikasi Warna Sarang

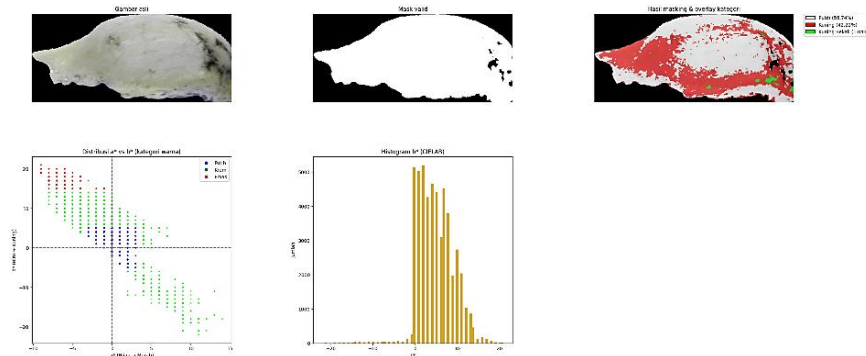
Setelah tahap deteksi bentuk, analisis warna dilakukan pada area sarang hasil *cropping* berdasarkan *bounding box* prediksi *YOLOV8*. Proses ini bertujuan untuk memastikan bahwa analisis warna hanya dilakukan pada area sarang yang relevan, sehingga gangguan visual seperti bulu dan latar belakang dapat diminimalkan. Untuk meminimalkan gangguan visual berupa bulu dan latar belakang, dilakukan pemisahan area sarang menggunakan analisis ruang warna HSV. Penggunaan ruang warna HSV pada tahap pra-pemrosesan efektif untuk pemisahan objek dari latar belakang karena memisahkan komponen warna (*Hue*) dari intensitas pencahayaan, sehingga mampu mendeteksi objek dengan akurat di bawah berbagai kondisi pencahayaan[34]. Hasil dari tahap ini adalah mask valid yang merepresentasikan area sarang yang layak untuk dianalisis warna.

Analisis warna dilakukan dengan mengonversi citra ke dalam ruang warna CIELAB, yang bersifat lebih mendekati persepsi visual manusia. Klasifikasi warna dilakukan berdasarkan nilai komponen a^* dan b^* pada setiap piksel valid. Berdasarkan kriteria yang telah ditetapkan, warna sarang diklasifikasikan ke dalam tiga kategori, yaitu putih, kuning, dan kuning sekali, di mana setiap piksel hanya dapat masuk ke satu kategori sehingga tidak terjadi tumpang tindih antar kelas warna.

Berdasarkan pengujian pada data uji, diperoleh persentase distribusi warna yang berbeda pada setiap sampel. Pada sampel A, persentase sebaran warna putih sebesar 35,08%, warna kuning sebesar 61,67%, dan warna kuning sekali sebesar 3,25%. Pada sampel B, diperoleh persentase sebaran warna putih sebesar 56,74%, warna kuning sebesar 42,22%, dan warna kuning sekali sebesar 1,04%. Pada sampel C, diperoleh persentase sebaran warna putih sebesar 23,04%, warna kuning sebesar 71,92%, dan warna kuning sekali sebesar 5,04% dapat dilihat pada Gambar 10, 11 dan 12.



Gambar 10. Prediksi Warna SBW A

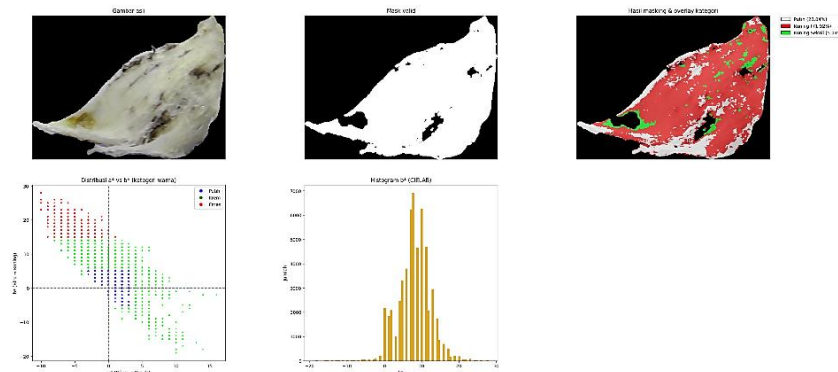


Gambar 11. Prediksi Warna SBW B

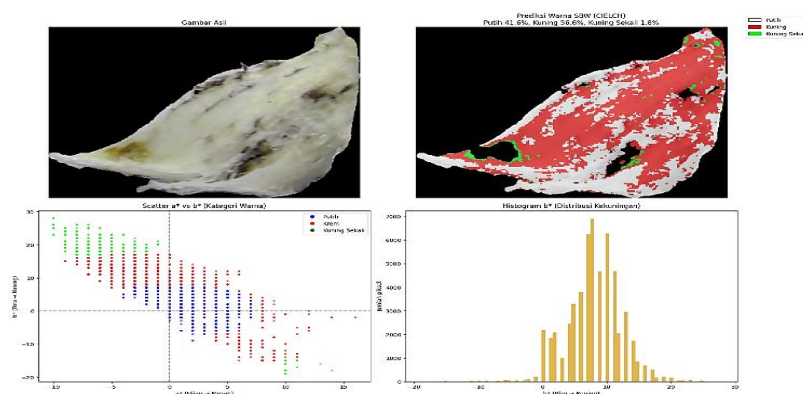
Sebagai bagian dari evaluasi metode analisis warna, dilakukan eksperimen komparatif menggunakan ruang warna CIELCH sebagai pendekatan alternatif terhadap CIELAB. Ruang warna CIELCH merupakan representasi polar dari CIELAB yang memisahkan informasi warna ke dalam komponen *lightness* (L^*), *chroma* (C^*), dan *hue angle* (h). Pada eksperimen ini, proses klasifikasi warna dilakukan berdasarkan nilai *chroma* (C^*) sebagai indikator tingkat kejenuhan warna.

Hasil eksperimen menunjukkan bahwa pendekatan berbasis CIELCH cenderung mengelompokkan sebagian area sarang yang secara visual berwarna kuning pucat ke dalam kategori putih dapat dilihat pada Gambar 13. Fenomena ini disebabkan oleh karakteristik warna sarang burung walet yang umumnya memiliki warna kuning lembut dengan tingkat kejenuhan relatif rendah. Pada kondisi tersebut, variasi warna lebih dominan direpresentasikan oleh arah warna dibandingkan tingkat kejenuhannya. Akibatnya, pemisahan

warna berbasis *chroma* menghasilkan distribusi warna yang kurang sejalan dengan persepsi visual pada citra asli, yang ditandai dengan meningkatnya proporsi warna putih dan berkurangnya area warna kuning.

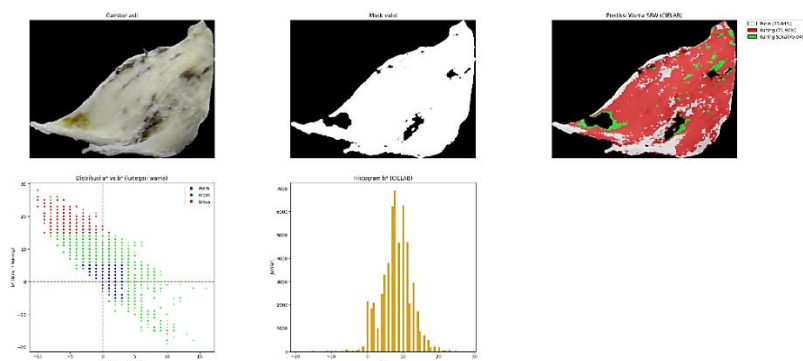


Gambar 12. Prediksi Warna SBW C



Gambar 13. Klasifikasi Warna Menggunakan CIELCH

Sebaliknya, pendekatan berbasis CIELAB menunjukkan kemampuan yang lebih baik dalam merepresentasikan sebaran warna kuning secara kontinu, karena klasifikasi warna didasarkan pada komponen b^* yang secara langsung merepresentasikan pergeseran spektrum warna dari biru ke kuning. Komponen ini terbukti lebih sensitif terhadap variasi tingkat kekuningan yang menjadi indikator utama dalam penilaian kualitas warna sarang burung walet dapat dilihat pada Gambar 14.



Gambar 14. Klasifikasi Warna Menggunakan CIELAB

Berdasarkan hasil komparasi tersebut, dapat disimpulkan bahwa meskipun CIELCH memiliki keunggulan dalam representasi warna berbasis tingkat kejenuhan, ruang warna CIELAB lebih sesuai dengan karakteristik warna sarang burung walet serta kebutuhan proses grading berbasis citra digital. Oleh karena itu, CIELAB dipilih sebagai pendekatan utama dalam penelitian ini karena mampu menghasilkan distribusi warna yang lebih konsisten secara visual dan lebih relevan untuk aplikasi penilaian kualitas sarang burung walet. Informasi persentase distribusi warna yang dihasilkan dapat digunakan sebagai dasar penentuan kategori warna dalam proses grading SBW, sehingga mendukung sistem penilaian yang lebih objektif dan konsisten dibandingkan penilaian visual secara manual.

3.2. Pembahasan

3.2.1. Deteksi Bentuk

Hasil penelitian menunjukkan bahwa model *YOLOv8n* mampu mendeteksi bentuk sarang burung walet dengan akurasi sangat tinggi ($mAP@0,5 = 99,5\%$). Tingginya akurasi ini dapat dijelaskan oleh beberapa faktor. Pertama, arsitektur *YOLOv8n* memiliki kemampuan ekstraksi fitur yang efisien sehingga mampu membedakan bentuk mangkok, oval, dan segitiga meskipun terdapat variasi posisi dan orientasi objek. Kedua, distribusi kelas yang seimbang dan jumlah objek uji yang memadai (480 objek) memungkinkan evaluasi performa yang representatif dan stabil. Ketiga, mekanisme *early stopping* terbukti efektif mencegah *overfitting*, sehingga kurva performa pada data validasi stabil.

Meskipun performa tinggi dicapai, model tetap memiliki keterbatasan. Deteksi bentuk dapat terpengaruh oleh kondisi pencahayaan ekstrim, objek dengan kontur tipis, atau tekstur putus. Pergeseran kecil *bounding box* prediksi dapat menurunkan nilai IoU meskipun tidak signifikan pada *mAP* keseluruhan. Strategi augmentasi citra dan integrasi sensor cahaya tambahan dapat meningkatkan *robustness* model pada kondisi operasional nyata.

Dari perspektif implementasi industri, kemampuan *YOLOv8n* untuk mendeteksi semua objek dengan recall tinggi dan membedakan kelas bentuk secara konsisten penting untuk grading otomatis berbasis conveyor. Hal ini memungkinkan penentuan kualitas sarang yang lebih objektif dan efisien dibandingkan penilaian manual. Perbandingan dengan MobileNet V2 FPNLite SSD menunjukkan bahwa *YOLOv8n* lebih *robust* terhadap variasi posisi, orientasi, dan kontur objek serta lebih efisien dalam ekstraksi fitur. Hasil ini sejalan dengan temuan Dolhopolov et al. (2024) pada aplikasi deteksi objek industri, sehingga memperkuat kontribusi penelitian ini dalam menyediakan sistem grading berbasis citra digital yang andal.

3.2.2. Klasifikasi Warna Sarang

Klasifikasi warna sarang menggunakan ruang warna CIELAB menunjukkan konsistensi tinggi dengan persepsi visual manusia. Dibandingkan dengan CIELCH, CIELAB lebih sensitif terhadap variasi kekuningan pada sarang, sehingga distribusi warna yang dihasilkan lebih representatif untuk penilaian kualitas. Hal ini sejalan dengan Rao et al. (2024), yang melaporkan bahwa CIELAB memberikan segmentasi warna lebih akurat dibandingkan ExG, ExR, ExGR, dan HSV, terutama pada kondisi pencahayaan variatif [35].

Keterbatasan pada klasifikasi warna termasuk pengaruh pencahayaan ekstrem, refleksi permukaan, atau variasi intensitas pada sarang pucat. Kondisi tersebut dapat menyebabkan sebagian piksel diklasifikasikan berbeda meskipun secara keseluruhan distribusi warna tetap akurat. Penerapan augmentasi citra, kalibrasi warna, atau sensor tambahan dapat meningkatkan keandalan klasifikasi warna pada kondisi nyata. Dari perspektif industri, informasi distribusi warna memungkinkan penetapan kategori grading yang jelas, misalnya putih, kuning, dan kuning sekali. Hal ini mendukung penilaian kualitas sarang yang lebih objektif, konsisten, dan efisien dibandingkan penilaian visual manual.

Secara kritis, penggunaan CIELAB memperkuat kontribusi penelitian ini dibandingkan metode sebelumnya yang kurang sensitif terhadap variasi warna lembut. Kombinasi deteksi bentuk menggunakan *YOLOv8n* dan klasifikasi warna berbasis CIELAB menghasilkan sistem grading SBW yang lebih andal, efisien, dan sesuai dengan standar industri.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan pendekatan prediksi grade sarang burung walet (SBW) berbasis multi-hirarki, yang terdiri dari deteksi bentuk sebagai level pertama dan analisis warna sebagai level berikutnya. Pendekatan ini dirancang untuk mendukung proses grading pada tahap bahan mentah dengan memberikan hasil yang lebih objektif dan konsisten dibandingkan metode penilaian visual manual yang selama ini bergantung pada subjektivitas evaluator.

Pada level pertama, deteksi bentuk SBW dilakukan menggunakan model *YOLOv8* untuk mengklasifikasikan tiga bentuk utama, yaitu mangkok, oval, dan segitiga. Hasil evaluasi pada data uji menunjukkan performa yang sangat tinggi dengan nilai $mAP@0,5$ sebesar 99,5%, serta nilai presisi dan *recall* yang mendekati sempurna pada seluruh kelas. Temuan ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan bentuk SBW secara akurat dan andal, sehingga layak digunakan sebagai dasar awal proses grading.

Pada level berikutnya, analisis warna dilakukan pada area sarang hasil *cropping* berdasarkan prediksi *bounding box* *YOLOv8* menggunakan pendekatan analisis piksel pada ruang warna CIELAB. Warna sarang berhasil diklasifikasikan ke dalam tiga kategori, yaitu putih, kuning, dan kuning sekali, tanpa adanya tumpang tindih antar kelas. Hasil pengujian menunjukkan adanya variasi persentase distribusi warna pada setiap sampel, yang mencerminkan karakteristik visual alami sarang burung walet. Representasi kuantitatif berupa persentase warna ini memberikan informasi yang lebih terukur dan dapat dijadikan dasar dalam penentuan kategori warna pada proses grading.

Secara keseluruhan, kombinasi deteksi bentuk berbasis *YOLOv8* dan analisis warna berbasis CIELAB terbukti mampu menghasilkan sistem grading SBW yang akurat, objektif, dan konsisten. Pendekatan yang

diusulkan memiliki potensi untuk diimplementasikan pada lingkungan industri guna meningkatkan efisiensi dan standarisasi proses grading sarang burung walet. Untuk penelitian selanjutnya, sistem ini dapat dikembangkan dengan menambahkan integrasi sistem menjadi *real-time* untuk inspeksi industri, analisis intensitas bulu menggunakan algoritma *deep learning* sebagai parameter kualitas tambahan, pengujian pada dataset industri berskala besar, serta eksplorasi metode klasifikasi warna tambahan atau kombinasi dengan sensor cahaya untuk meningkatkan akurasi pada kondisi pencahayaan ekstrem.

REFERENSI

- [1] S. JENDERAL, *Analisis Kinerja Perdagangan Sarang Burung Walet*. Pusat Data dan Sistem Informasi Pertanian Kementerian Pertanian, 2024. [Online]. Available: <https://satudata.pertanian.go.id/details/publikasi/787>
- [2] R. Widya Maharani, R. Setya Wijaya, and Marseto, "Potensi dan Daya Saing Ekspor Sarang Burung Walet Indonesia di Pasar China," *J. Ilm. Wahana Pendidik.*, vol. 2024, no. 15, pp. 630–639, 2024, doi: <https://doi.org/10.5281/zenodo.13831346> p-ISSN:
- [3] R. M. Ibrahim, N. N. M. Nasir, M. Z. A. Bakar, R. Mahmud, and N. A. A. Razak, "The Authentication and Grading of Edible Bird's Nest by Metabolite, Nutritional, and Mineral Profilin," *Foods*, vol. 10, no. 7, pp. 1–14, 2021, doi: <https://doi.org/10.3390/foods10071574>.
- [4] B. H. Yeo *et al.*, "Potential Residual Contaminants in Edible Bird's Nest," *Front. Pharmacol.*, vol. 12, no. March, pp. 1–15, 2021, doi: [10.3389/fphar.2021.631136](https://doi.org/10.3389/fphar.2021.631136).
- [5] S. Rahayu, W. Suryapratama, F. M. Suhartati, M. Bata, E. A. Rimbawanto, and B. Hartoyo, "Quality of edible bird's nest treated by keratinolytic enzymes-based cleaning solution," *Food Res.*, vol. 8, no. 2, pp. 299–307, 2024, doi: [10.26656/fr.2017.8\(2\).287](https://doi.org/10.26656/fr.2017.8(2).287).
- [6] J. Parhusip, Hanna Arini; Trihandaru, Suryasatriya; Hartomo, Kristoko Dwi; Kom, M.; Lewerissa, Karina Bianca; Mahastanti, Linda Ariany; Indrajaya, Denny; Hartanto, *Manajemen Dan Teknologi Dalam Industri Sarang Burung Walet Di Pt Waleta Asia Jaya*. Uwais Inspirasi Indonesia, 2025. [Online]. Available: https://books.google.com/books?hl=en&lr=&id=ynpJEQAAQBAJ&oi=fnd&pg=PP1&dq=burung+walet&ots=B_f0POBe4t&sig=YG0bud1HIGIMDLjA_yECFRgg_bU
- [7] A. Prinato and A. S. Purnomo, "Implementasi Metode Weighted Product dalam Sistem Pendukung Keputusan Penentuan Kualitas Sarang Burung Walet," *J. Syntax Admiration*, vol. 4, no. 12, pp. 2516–2528, 2024, doi: [10.46799/jsa.v4i12.946](https://doi.org/10.46799/jsa.v4i12.946).
- [8] Ansari and J. Rifani, "Upaya Mempertahankan Kualitas Dan Harga Sarang Burung Walet Terhadap Harga Penjualan Di Desa Telaga Mas Kecamatan Danau Panggang Kabupaten Hulu Sungai Utara," *J. Adm. Bisnis*, vol. 1, no. 1, pp. 54–61, 2024, [Online]. Available: <https://ejurnal.stiaamuntai.ac.id/index.php/JAB/article/view/528>
- [9] M. N. G. Amin, G. Soegiarto, and L. Wulandari, "The physicochemical and antioxidant activity of Realfood' hydrolysed bird nest (RHBN)," *Appl. Food Res.*, vol. 5, no. 1, p. 100993, 2025, doi: [10.1016/j.afres.2025.100993](https://doi.org/10.1016/j.afres.2025.100993).
- [10] M. Kan, H. Ren, J. Du, and Y. Sun, "The Effect of Hydrolysis on the Bioactivity of Edible Bird's Nest: A Systematic Review," *J. Futur. Foods*, 2025, doi: [10.1016/j.jfutfo.2025.05.007](https://doi.org/10.1016/j.jfutfo.2025.05.007).
- [11] Z. Yin, L. Sin, N. Aqilah, M. Zaini, and S. Fazry, "Development of a novel yoghurt enriched with fermented edible bird's nest: Physicochemical, antioxidative, and microbiological stability," *Appl. Food Res.*, vol. 5, no. 2, p. 101408, 2025, doi: [10.1016/j.afres.2025.101408](https://doi.org/10.1016/j.afres.2025.101408).
- [12] W. Zhang *et al.*, "Maternal supplementation with edible birds' nest during gestation and lactation enhances intestinal barrier function by upregulating Claudin-1 in rat offspring," *J. Funct. Foods*, vol. 116, p. 106177, 2024, doi: [10.1016/j.jff.2024.106177](https://doi.org/10.1016/j.jff.2024.106177).
- [13] F. Agus, E. Sulfika, and G. Mahendra Putra, "Analisis Kualitas Sarang Burung Walet Menggunakan Metode Fuzzy Tsukamoto," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 2, pp. 391–398, 2025, doi: [10.25126/jtiik.2025129441](https://doi.org/10.25126/jtiik.2025129441).
- [14] M. Ismail and R. Yulvianda, "Penerapan Data Mining Dengan Metode K-Nearest Neighbor Terhadap Klasifikasi Sarang Walet," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 3, pp. 1220–1228, 2023, doi: [10.30865/mib.v7i3.6431](https://doi.org/10.30865/mib.v7i3.6431).
- [15] D. Indrajaya, A. Setiawan, D. Hartanto, and H. Hariyanto, "Object Detection to Identify Shapes of Swallow Nests Using a Deep Learning Algorithm," *Khazanah Inform. J. Ilmu Komput. dan Inform.*, vol. 8, no. 2, pp. 139–148, 2022, doi: [10.23917/khif.v8i2.16489](https://doi.org/10.23917/khif.v8i2.16489).
- [16] Y. Zhang *et al.*, "Design of an intelligent grading system for Chinese water chestnuts utilizing advanced artificial intelligence methods," *Eng. Appl. Artif. Intell.*, vol. 160, p. 112070, Nov. 2025, doi: [10.1016/J.ENGAPPAI.2025.112070](https://doi.org/10.1016/J.ENGAPPAI.2025.112070).
- [17] P. Pugazhendi, "Digitized visual measurement system using MobileNetV2-CBAM for automated sapota quality grading," *Meas. Digit.*, vol. 6, no. 1, pp. 8–12, 2026, doi: <https://doi.org/10.1016/j.meadig.2025.100020>.

- [18] L. Xue *et al.*, “DBH-YOLO: A novel algorithm for surface defects detection of postharvest blue honeysuckle berry fruit,” *Postharvest Biol. Technol.*, vol. 233, p. 114045, Mar. 2026, doi: 10.1016/J.POSTHARVBIO.2025.114045.
- [19] H. Ma *et al.*, “Segmentation of dense overlapping *Agaricus bisporus* and harvest timing planning Using *YOLOv8n*-USD with KD-Tree nearest-neighbour search,” *Inf. Process. Agric.*, Feb. 2026, doi: 10.1016/J.INPA.2026.02.005.
- [20] M. Filgueiras Rebelo de Matos *et al.*, “Innovative methodological approach using CIELab and dye screening for chemometric classification and HPLC for the confirmation of dyes in cassava flour: A contribution to product quality control,” *Food Chem.*, vol. 365, no. 1–9, 2021, doi: 10.1016/j.foodchem.2021.130446.
- [21] L. Maulana, Y. G. Bihanda, and Y. A. Sari, “Color space and color channel selection on image segmentation of food images,” *Regist. J. Ilm. Teknol. Sist. Inf.*, vol. 6, no. 2, pp. 141–151, 2020, doi: 10.26594/register.v6i2.2061.
- [22] V. Moya, M. Guerra, K. Pazmiño, F. Abedrabbo, F. A. Chicaiza, and D. Pozo-Espín, “Tomato classification with *YOLOv8*: Enhancing automated sorting and quality assessment,” *Smart Agric. Technol.*, vol. 12, p. 101221, 2025, doi: 10.1016/j.atech.2025.101221.
- [23] Z. Wu, H. Zhang, and C. Fang, “Research on machine vision online monitoring system for egg production and quality in cage environment,” *Poult. Sci.*, vol. 104, no. 1, p. 104552, 2025, doi: 10.1016/j.psj.2024.104552.
- [24] H. Zhong and R. Wang, “A visual-degradation-inspired model with HSV color-encoding for contour detection,” *J. Neurosci. Methods*, vol. 369, p. 109423, 2022, doi: 10.1016/j.jneumeth.2021.109423.
- [25] A. Horta-Velázquez, G. Ramos-Ortiz, and E. Morales-Narváez, “The optimal color space enables advantageous smartphone-based colorimetric sensing,” *Biosens. Bioelectron.*, vol. 273, p. 117089, 2025, doi: 10.1016/j.bios.2024.117089.
- [26] D. Hema and D. S. Kannan, “Interactive Color Image Segmentation using HSV Color Space,” *Sci. Technol. J.*, vol. 7, no. 1, pp. 37–41, 2020, doi: 10.22232/stj.2019.07.01.05.
- [27] L. Rey *et al.*, “A Performance Analysis of You Only Look Once Models for Deployment on Constrained Computational Edge Devices in Drone Applications,” *Electronics*, vol. 14, no. 3, pp. 1–25, 2025, doi: <https://doi.org/10.3390/electronics14030638>.
- [28] C. Beldek, J. Cunningham, M. Aydin, E. Sariyildiz, S. L. Phung, and G. Alici, “Sensing-based Robustness Challenges in Agricultural Robotic Harvesting,” *IEEE*, pp. 1–6, 2025, doi: 10.1109/ICM62621.2025.10934824.
- [29] Y. Zhang *et al.*, “Integrating phenotypic analyses and color parameters: a multidimensional framework for precise color characterization in eggplant fruit,” *Front. Plant Sci.*, vol. 16, pp. 1–12, 2025, doi: 10.3389/fpls.2025.1689896.
- [30] H. Boruczkowska, T. Boruczkowski, M. Bronkowska, M. Prajzner, and E. Rytel, “Comparison of Colour Measurement Methods in the Food Industry,” *Processes*, vol. 13, no. 5, pp. 1–14, 2025, doi: <https://doi.org/10.3390/pr13051268>.
- [31] M. Huang, W. Mi, and Y. Wang, “EDGS-*YOLOv8*: An Improved *YOLOv8* Lightweight UAV Detection Model,” *drones*, vol. 8, no. 7, pp. 1–21, 2024, doi: 10.3390/drones8070337.
- [32] S. Dolhopolov, T. Honcharenko, D. Chernyshev, O. Panina, and A. Makhynia, “Advancing automated quality control in automotive manufacturing: a comparative analysis of *YOLOv8*, *YOLOv9*, and *YOLOv10* for vehicle damage detection,” in *9th International Conference on Digital Technologies in Education, Science and Industry (DTESI 2024)*, Almaty, Kazakhstan: CEUR Workshop Proceedings, 2024, pp. 4–12. [Online]. Available: https://www.researchgate.net/publication/392787673_Advancing_automated_quality_control_in_automotive_manufacturing_a_comparative_analysis_of_YOLOv8_YOLOv9_and_YOLOv10_for_vehicle_damage_detection
- [33] L. E. X. L. O. F. L. Self-government, “Novel Approach For Object Detection In Embedded Systems Using YOLO,” *LEX LOCALIS*, vol. 23, no. 11, pp. 710–719, 2025, doi: <https://doi.org/10.52152/801932>.
- [34] Rizka, S. Nasution, F. Aulia, and Supiyandi, “Penerapan Metode Segmentasi Warna HSV untuk Deteksi Objek Berbasis Warna pada Citra Digital,” *Router J. Tek. Inform. dan Terap.*, vol. 3, no. 4, pp. 11–24, 2025, doi: <https://doi.org/10.62951/router.v3i4.706>.
- [35] K. K. Rao, R. K. B. S. Rao, and L. K., “Development of ExG, ExR, ExGR, HSV, CIELAB Images from RGB Images Using Image Segmentation Algorithm in Computer Vision Based Herbicide Spraying Applications,” *J. Sci. Res. Reports*, vol. 30, no. 10, pp. 501–508, 2024, doi: 10.9734/jsrr/2024/v30i102477.