

## Pengembangan model klasifikasi kualitas sarang burung walet berbasis CNN dengan *transfer learning* MobileNetV2

Hasni Anas\*, Kusrini

Universitas Amikom Yogyakarta

Jl. Ring Road Utara, Condong Catur, Sleman, Yogyakarta

Email: \*hasnianas84@students.amikom.ac.id

---

### Riwayat Artikel

Diterima:  
09-07-2025

Direvisi:  
27-07-2025

Disetujui:  
05-08-2025

---

### Abstract

*The quality of edible bird's nests (EBN) is a crucial factor in determining their market value, which necessitates an accurate, automated classification system. This study aims to develop a quality classification model for EBN using a Convolutional Neural Network (CNN) approach with transfer learning based on the MobileNetV2 architecture. The dataset consists of 3,406 EBN images collected directly from farmers, processed through aggressive data augmentation and background removal to emphasize the main object. The data were evenly split into training (2,723 images) and validation (683 images) sets, covering three quality classes: high, medium, and low. The model was trained in two phases: initial training with frozen base layers, followed by fine-tuning. Evaluation results showed an increase in validation accuracy from 93% to 97% after fine-tuning, with average precision, recall, and F1-score values of 0.97. The confusion matrix indicated high classification consistency, with most predictions aligned along the diagonal. This study contributes to the development of a high-accuracy image-based EBN quality classification system by integrating contour-based preprocessing, data augmentation, and CNN architecture optimization. The resulting model offers a reliable automated solution suitable for industrial implementation to support objective and efficient EBN quality sorting*

**Keywords:** *edible bird' nest, Convolutional Neural Network, transfer learning, MobileNetV2, image classification*

### Abstrak

Kualitas sarang burung walet merupakan faktor penting dalam menentukan nilai jual, sehingga diperlukan sistem klasifikasi yang akurat dan otomatis. Penelitian ini bertujuan mengembangkan model klasifikasi mutu sarang burung walet menggunakan algoritma *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* berbasis arsitektur MobileNetV2. Dataset yang digunakan terdiri atas 3.406 citra sarang burung walet yang diperoleh langsung dari petani, kemudian diproses melalui augmentasi agresif dan penghapusan latar belakang guna menyoroti objek utama. Data dibagi secara seimbang ke dalam data pelatihan sebanyak 2.723 citra dan data validasi sebanyak 683 citra, mencakup tiga kelas kualitas: tinggi, sedang, dan rendah. Model dilatih dalam dua tahap, yaitu pelatihan awal (*frozen base*) dan *fine-tuning*. Hasil evaluasi menunjukkan peningkatan akurasi dari 93%

menjadi 97% setelah proses *fine-tuning*, dengan nilai *precision*, *recall*, dan *F1-score* rata-rata sebesar 0,97. Hasil *confusion matrix* memperlihatkan akurasi klasifikasi yang tinggi dan prediksi dominan berada pada diagonal utama. Penelitian ini berkontribusi dalam mengembangkan sistem klasifikasi mutu sarang burung walet berbasis citra dengan akurasi tinggi melalui integrasi pra-pemrosesan berbasis kontur, augmentasi data, dan optimasi arsitektur CNN. Model yang dihasilkan berpotensi untuk diimplementasikan pada industri guna mendukung proses penyortiran sarang burung walet secara objektif dan efisien.

**Kata kunci:** sarang burung walet, *Convolutional Neural Network*, *transfer learning*, MobileNetV2, klasifikasi citra

## Pendahuluan

Indonesia merupakan salah satu negara penghasil dan pengeksport sarang burung walet terbesar di dunia, menjadikan komoditas ini sebagai salah satu unggulan dalam ekspor pertanian nasional. Sekitar 98% pasokan sarang burung walet di pasar global berasal dari Indonesia, yang dikenal memiliki karakteristik produk yang lebih higienis, berwarna lebih putih, dan memiliki ketebalan ideal [1]. Sarang burung walet merupakan produk alami yang berasal dari air liur burung walet (*Aerodramus fuciphagus*) yang dihasilkan melalui sekresi protein dari kelenjar sublingual selama musim berkembang biak [2], [3]. Struktur sarang ini terdiri atas glikoprotein kompleks yang mengeras saat terpapar udara, membentuk jaringan biomaterial yang unik.

Seiring dengan perkembangan teknologi, *Convolutional Neural Network* (CNN) menunjukkan efektivitas yang tinggi dalam menyelesaikan tugas klasifikasi citra. CNN dikenal unggul dalam mengekstraksi representasi spasial-hierarkis dari citra secara otomatis melalui arsitektur berlapis, sehingga sangat potensial untuk diterapkan dalam klasifikasi mutu sarang burung walet. Salah satu arsitektur CNN yang efisien untuk sistem klasifikasi berbasis citra dengan keterbatasan komputasi adalah MobileNetV2.

Penelitian ini secara khusus menerapkan MobileNetV2 dengan pendekatan *transfer learning* dan strategi *fine-tuning* untuk mengoptimalkan performa model dalam klasifikasi mutu sarang burung walet. Strategi ini memungkinkan model menyesuaikan bobot *pretrained* terhadap karakteristik spesifik domain citra guna memperoleh hasil klasifikasi yang lebih akurat dan generalis. Namun penelitian ini berbeda dari penelitian sebelumnya di mana penelitian ini mengusulkan *pipeline* klasifikasi visual berbasis CNN dengan MobileNetV2 yang dioptimalkan melalui *fine-tuning* dan *balancing* dataset secara menyeluruh. Dengan demikian, pendekatan ini tidak hanya mendorong inovasi teknologi klasifikasi di bidang pertanian digital, tetapi juga berkontribusi terhadap peningkatan daya saing produk ekspor nasional melalui otomatisasi penilaian mutu. Dengan hasil klasifikasi yang presisi dan otomatis, model ini diharapkan dapat diintegrasikan ke dalam sistem industri untuk mendukung proses penyortiran sarang burung walet secara efisien dan objektif.

Beberapa penelitian sebelumnya mendemonstrasikan efektivitas berbagai pendekatan dalam klasifikasi sarang walet. Kombinasi fitur bentuk dan algoritma *Support Vector Machine* (SVM) digunakan untuk mengklasifikasi kualitas sarang walet, dengan akurasi mencapai 89,3% [4]. Selain itu telah dikembangkan sistem deteksi bentuk sarang menggunakan arsitektur SSD-MobileNetV2 untuk mengklasifikasikan bentuk ke dalam tiga kategori, yaitu *oval*, *bowl*, dan *angular*, namun hanya memperoleh *mean Average Precision* (mAP) sebesar 61,91% [5]. Metode Fuzzy Tsukamoto juga telah digunakan untuk mengklasifikasikan kualitas sarang burung walet berdasarkan lima parameter, yaitu warna, jumlah bulu, jenis, kondisi fisik, dan kadar air. Hasil klasifikasi dibagi ke dalam tiga kategori mutu: Sangat Bagus, Bagus, dan Tidak Bagus. Dengan pengujian terhadap 100 data, metode ini berhasil mencapai akurasi 97%, yang menunjukkan bahwa pendekatan logika fuzzy memiliki potensi besar dalam otomatisasi proses klasifikasi [6].

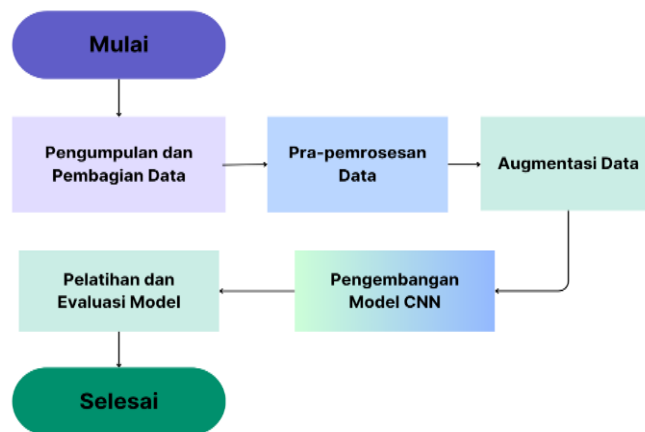
Sejumlah penelitian terdahulu menekankan pentingnya augmentasi data dalam meningkatkan performa model CNN. Kualitas maupun kuantitas data latih memiliki peran krusial terhadap kinerja CNN, oleh karenanya diperlukan penerapan teknik augmentasi dan regularisasi [7]. Sementara itu, Zheng merancang strategi augmentasi yang komprehensif dan berhasil meningkatkan akurasi CNN hingga 93,41% pada dataset CIFAR-10 [8]. Dalam literatur yang lain, Yoo dan Kang juga memperkenalkan pendekatan augmentasi adaptif berbasis kelas untuk memperkuat kemampuan generalisasi model [9]. Di sisi lain, Jayadi mengembangkan sistem klasifikasi kebersihan sarang burung walet berbasis *computer vision* untuk membedakan antara lubang alami dan kotoran pada sarang. Dalam penelitiannya, digunakan dua algoritma, yaitu *Random Forest* dan SVM. Hasil evaluasi menunjukkan bahwa *Random Forest* mampu mencapai akurasi sebesar 97,5%, lebih tinggi dibandingkan SVM yang hanya memperoleh akurasi 84,1% [10].

Penelitian ini bertujuan untuk membangun model klasifikasi kualitas sarang burung walet ke dalam tiga kelas utama, yaitu tinggi, sedang, dan rendah. Sebanyak 3.406 citra yang telah melalui proses pra-pemrosesan berupa augmentasi citra seperti *rotasi*, *flipping*, *horizontal*, *zooming*, *shifting* dan penghapusan latar belakang yang dikumpulkan langsung dari para petani di Desa Soni Kecamatan Dampal Selatan Kabupaten Tolitoli Provinsi Sulawesi Tengah. Kategori mutu ditentukan berdasarkan ciri visual masing-masing, yaitu: (1) kualitas tinggi ditandai oleh bentuk yang padat dan simetris, warna cerah, bersih, serta tekstur yang halus; (2) kualitas sedang memiliki bentuk agak longgar, warna agak gelap, terdapat bercak kecil, dan kerusakan ringan; serta (3) kualitas rendah dicirikan oleh bentuk yang tidak beraturan, warna gelap, bercak yang dominan, dan adanya kotoran maupun kerusakan yang mencolok.

Guna mengatasi keterbatasan jumlah data, penelitian ini menerapkan teknik augmentasi untuk meningkatkan keragaman data latih. Model CNN yang digunakan dibangun menggunakan arsitektur MobileNetV2 dan diimplementasikan dalam dua tahap, yaitu pelatihan awal dengan membekukan lapisan dasar (*frozen base*), kemudian dilanjutkan dengan proses *fine-tuning* untuk menyesuaikan bobot model terhadap karakteristik data spesifik. Pendekatan ini berbeda dari studi [5] yang menitikberatkan pada bentuk sarang, serta pendekatan *non-deep learning* seperti SVM pada penelitian [4], maupun metode logika fuzzy pada penelitian [6]. Penelitian ini memberikan kontribusi melalui pengembangan sistem klasifikasi mutu visual sarang burung walet secara menyeluruh berbasis CNN, yang dipadukan dengan teknik pra-pemrosesan khusus dan strategi augmentasi data. Dengan demikian, pendekatan ini diharapkan mampu menghasilkan solusi klasifikasi otomatis yang akurat, efisien, serta dapat diterapkan secara objektif dalam proses penilaian mutu sarang burung walet di industri.

### Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimen terapan untuk mengembangkan dan mengevaluasi model klasifikasi kualitas sarang burung walet berbasis CNN. CNN dipilih karena kemampuannya dalam mengenali pola visual yang kompleks secara otomatis dan efisien, sehingga sesuai untuk menangani variasi bentuk, tekstur, dan warna sarang.



Gambar 1 Alur penelitian

Tujuan utama penelitian ini adalah membuktikan bahwa CNN, khususnya melalui pendekatan *transfer learning*, dapat menjadi solusi akurat dalam menilai kualitas sarang burung walet berbasis citra. Penelitian dilaksanakan secara sistematis melalui beberapa tahap, yaitu pengumpulan data citra, pra-pemrosesan untuk menghasilkan input yang bersih dan seragam, augmentasi data untuk memperkaya variasi pelatihan, pembangunan model CNN menggunakan arsitektur MobileNetV2, pelatihan model, dan evaluasi performa menggunakan metrik klasifikasi. Setiap tahap

dirancang dengan mempertimbangkan keterbatasan data dan efisiensi komputasi. Alur lengkap penelitian disajikan pada Gambar 1.

Penelitian ini menggunakan 3.406 citra sarang burung walet yang diperoleh langsung dari petani di Desa Soni, Kecamatan Dampal Selatan, Kabupaten Tolitoli, Provinsi Sulawesi Tengah. Seluruh citra telah melalui tahap pra-pemrosesan yang mencakup augmentasi gambar, seperti rotasi, flipping horizontal, zooming, shifting, serta penghapusan latar belakang untuk memperkaya variasi data sekaligus memastikan bahwa objek utama tetap menjadi fokus klasifikasi. Dataset tersebut dikategorikan menjadi tiga kelas kualitas, yaitu: kualitas tinggi sebanyak 1.111 gambar, kualitas sedang sebanyak 1.104 gambar, dan kualitas rendah sebanyak 1.191 gambar. Seluruh citra disimpan dalam format JPG dengan resolusi rata-rata  $2.448 \times 3.264$  piksel. Selanjutnya, dataset dibagi secara proporsional dengan rasio 80:20, yaitu 2.723 gambar (80%) untuk pelatihan dan 683 gambar (20%) untuk validasi. Kategori mutu ditentukan berdasarkan ciri visual masing-masing, yaitu: (1) kualitas tinggi ditandai oleh bentuk yang padat dan simetris, warna cerah, bersih, serta tekstur yang halus; (2) kualitas sedang memiliki bentuk agak longgar, warna agak gelap, terdapat bercak kecil, dan kerusakan ringan; serta (3) kualitas rendah dicirikan oleh bentuk yang tidak beraturan, warna gelap, bercak yang dominan, dan adanya kotoran maupun kerusakan yang mencolok. Ilustrasi sampel sarang burung walet disajikan pada Gambar 2, sedangkan klasifikasi mutu dan distribusi data per kelas masing-masing ditampilkan pada Tabel 1 dan Tabel 2.



Gambar 2 Gambar sarang burung walet

Tabel 1 Kategori sarang burung walet

Kelas	Bentuk Sarang	Warna	Kondisi Umum
Tinggi	Simetris dan padat	Cerah	Bersih, tanpa bercak atau kerusakan
Sedang	Agak longgar	Agak Gelap	Bercak kecil, kerusakan minor
Rendah	Tidak teratur	Gelap	Banyak bercak, kotoran atau cacat terlihat

Tabel 2 Distribusi data gambar per kelas

Kelas	Train	Validasi	Total
Tinggi	888	223	1111
Sedang	883	221	1104
Rendah	952	239	1191
<b>Total</b>	<b>2723</b>	<b>683</b>	<b>3406</b>

Tahapan pra-pemrosesan data dilakukan secara berurutan dimulai dari penghapusan latar belakang untuk memfokuskan area objek utama, yaitu sarang burung walet. Setelah itu, citra dikonversi ke dalam format *grayscale* dan diterapkan Gaussian blur guna mengurangi *noise*. Langkah berikutnya adalah deteksi tepi menggunakan algoritma Canny untuk menyoroti batas objek, yang kemudian digunakan sebagai acuan dalam melakukan *cropping* berdasarkan *bounding box*. Citra hasil *crop* kemudian diubah ukurannya menjadi  $224 \times 224$  piksel sesuai dengan standar input model MobileNetV2. Terakhir, seluruh nilai piksel dinormalisasi ke rentang 0 hingga 1 guna meningkatkan efisiensi dan kestabilan pelatihan model CNN. Berikut adalah tahapan pra-pemrosesan yang dapat dilihat pada Gambar 3.



**Gambar 3** Tahapan pra-pemrosesan data

Semua tahapan dilakukan secara seragam terhadap seluruh citra, baik untuk data pelatihan maupun validasi. Dengan prosedur pra-pemrosesan yang terstandarisasi, model CNN dapat dilatih dengan data yang lebih bersih, relevan, dan bebas dari gangguan visual, sehingga meningkatkan peluang akurasi klasifikasi yang optimal. Berikut dapat dilihat pada Gambar 4 sarang burung walet sebelum diproses dan hasil setelah pra-pemrosesan data.



**Gambar 4** Sarang burung walet sebelum diproses dan setelah pra-pemrosesan data

Tahapan augmentasi data dilakukan untuk memperluas keragaman data pelatihan secara sintesis tanpa mengubah label asli. Penerapan teknik augmentasi hanya dilakukan pada data pelatihan guna memperkaya variasi visual dan mengurangi risiko *overfitting*. Augmentasi telah menjadi teknik umum dan efektif dalam pelatihan model CNN, terutama ketika dataset asli terbatas atau memiliki homogenitas tinggi [11]. Berikut ini adalah teknik augmentasi yang digunakan dalam penelitian: (1) Rotasi gambar  $10^{\circ}$ – $30^{\circ}$  untuk variasi sudut; (2) *Flipping* horizontal dan vertikal agar model tetap mengenali gambar meski terbalik; (3) *Zooming* untuk melatih model pada objek dengan ukuran berbeda; (4) *Shifting* posisi gambar agar model lebih fleksibel terhadap

letak objek; dan (5) Penyesuaian kecerahan dan kontras untuk mengatasi perbedaan pencahayaan.

CNN merupakan salah satu arsitektur *deep learning* yang secara khusus dikembangkan untuk menangani data berstruktur grid, seperti gambar dua dimensi. CNN memiliki kemampuan untuk mengekstraksi fitur spasial secara otomatis melalui pembelajaran berlapis, sehingga menjadi pilihan utama dalam berbagai aplikasi visi komputer, termasuk klasifikasi gambar, deteksi objek, dan segmentasi citra [12], [13]. Arsitektur ini terdiri atas sejumlah komponen penting, seperti fungsi aktivasi, fungsi *loss*, dan metrik evaluasi yang digunakan dalam mengukur kinerja klasifikasi mutu sarang burung walet. Fungsi aktivasi yang digunakan pada lapisan konvolusi adalah *Rectified Linear Unit* (ReLU) [14], sebagaimana dijelaskan pada Persamaan (1).

$$f(x) = \max(0, x) \quad (1)$$

Untuk menghasilkan probabilitas dari masing-masing kelas pada lapisan output, digunakan fungsi aktivasi Softmax, seperti ditunjukkan pada Persamaan (2).

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2)$$

Fungsi *loss* yang digunakan dalam pelatihan model CNN adalah *categorical cross-entropy*, sebagaimana dirumuskan pada Persamaan (3).

$$L = - \sum_{i=1}^K y_i \log(\hat{y}_i) \quad (3)$$

Untuk menilai kinerja model, digunakan beberapa metrik evaluasi yaitu akurasi, presisi, recall, dan F1-score. Persamaan untuk masing-masing metrik ditunjukkan pada Persamaan (4) hingga (7) [15].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

Pada Persamaan (4) hingga (7), istilah TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*) merujuk pada hasil prediksi model yang dibandingkan dengan label sebenarnya. Evaluasi dilakukan untuk setiap kelas secara terpisah, kemudian dihitung nilai rata-ratanya menggunakan pendekatan *macro average*. Penilaian ini memberikan gambaran performa model secara menyeluruh, khususnya dalam konteks klasifikasi multi-kelas.

Dalam upaya mencapai performa yang optimal, pengembangan model dilakukan menggunakan arsitektur CNN berbasis MobileNetV2 yang telah dilatih sebelumnya pada dataset *ImageNet*. CNN sendiri terdiri atas sejumlah lapisan inti yang saling terhubung dan bekerja secara berurutan dalam memproses citra digital. Pelatihan dilakukan dalam dua tahap, yakni *frozen base training* dan *fine-tuning*. Pada tahap pertama, seluruh bobot dari model *pre-trained* dibekukan agar hanya lapisan klasifikasi yang dilatih. Strategi ini bertujuan untuk mengurangi risiko *overfitting* terhadap dataset yang terbatas. Selanjutnya, pada tahap *fine-tuning*, sebagian lapisan awal dari MobileNetV2 dibuka agar model dapat menyesuaikan fitur dasar dengan karakteristik spesifik dari citra sarang burung walet. Rincian pengaturan model dapat dilihat pada Tabel 3 yang memuat konfigurasi *hyperparameter* CNN secara lengkap.

**Tabel 3** *Hyperparameter* model CNN

<b>Parameter</b>	<b>Nilai</b>
Arsitektur dasar	MobileNetV2 (pretrained on ImageNet)
Ukuran input gambar	224 × 224 piksel
Jumlah kelas	3 (tinggi, sedang, rendah)
<i>Optimizer</i>	Adam
<i>Learning rate</i> awal	0.0001
<i>Batch size</i>	32
<i>Epoch</i> maksimum	30
<i>Early stopping</i>	5 <i>patience</i>
<i>Loss function</i>	<i>Categorical Crossentropy</i>
Aktivasi akhir	Softmax

MobileNetV2 merupakan arsitektur jaringan saraf konvolusional CNN yang dirancang khusus untuk efisiensi tinggi dalam klasifikasi citra pada perangkat dengan keterbatasan daya komputasi, seperti perangkat mobile dan embedded system. Arsitektur ini diperkenalkan sebagai penyempurnaan dari MobileNetV1, dengan menghadirkan dua komponen utama, yaitu *depthwise separable convolution* dan *inverted residual block* [16].

Keunggulan MobileNetV2 terletak pada penggunaan fungsi aktivasi ReLU6, *batch normalization*, serta desain struktur yang efisien. Hal ini membuatnya sangat sesuai untuk pendekatan *transfer learning* dan *fine-tuning* pada dataset citra berskala kecil hingga menengah. Selain memiliki ukuran model yang ringan, MobileNetV2 juga mampu mempertahankan akurasi yang kompetitif dibandingkan arsitektur CNN lainnya, sehingga ideal diterapkan pada aplikasi real-time seperti klasifikasi mutu visual sarang burung walet.

Pemilihan MobileNetV2 dilakukan secara terarah karena model ini memiliki efisiensi tinggi dan ringan secara komputasi, sehingga sesuai untuk pengembangan sistem klasifikasi berbasis perangkat terbatas seperti sistem *edge* atau *mobile*. Penelitian ini tidak membandingkan dengan arsitektur lain karena fokus utama adalah

mengevaluasi performa MobileNetV2 melalui pendekatan dua tahap pelatihan. Evaluasi performa model dilakukan dengan mengukur nilai akurasi, presisi, *recall*, dan *F1-score* guna memastikan keandalan model dalam mengklasifikasikan kualitas sarang burung walet.

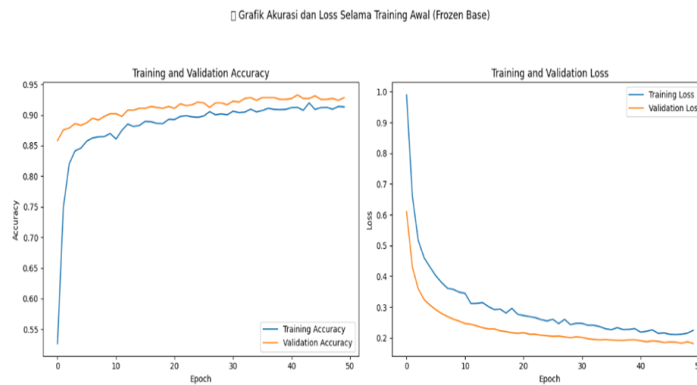
Model dilatih menggunakan 2.723 citra latih dan divalidasi pada 683 citra dari tiga kelas kualitas sarang burung walet yang seimbang, setelah melalui proses augmentasi dan penghapusan latar belakang. Arsitektur MobileNetV2 diterapkan dengan pendekatan transfer learning dan fine-tuning dalam dua tahap: pertama dengan membekukan seluruh lapisan, kemudian membuka sebagian lapisan akhir untuk menyesuaikan bobot terhadap data spesifik. Proses pelatihan menggunakan algoritma optimasi Adam, fungsi loss *categorical cross entropy*, dan strategi *early stopping* dengan *patience* sebesar 5 untuk mencegah *overfitting*. Evaluasi dilakukan berdasarkan akurasi, *precision*, *recall*, dan *F1-score*, serta didukung oleh *confusion matrix* yang menunjukkan dominasi prediksi pada diagonal utama, menandakan performa klasifikasi yang sangat baik. Narasi ini mendukung validitas dan kontribusi model dalam pengklasifikasian kualitas sarang burung walet secara efisien dan akurat.

### Hasil dan Pembahasan

Model CNN yang digunakan dalam penelitian ini berbasis arsitektur MobileNetV2, dengan tujuan mengklasifikasikan citra sarang burung walet ke dalam tiga kelas kualitas: tinggi, sedang, dan rendah. Proses pelatihan dilakukan dalam dua tahap, yakni pelatihan awal (*training* awal) dengan base model yang dibekukan (*frozen base*), kemudian dilanjutkan dengan tahap *fine-tuning* untuk meningkatkan performa model secara keseluruhan. Pada tahap pelatihan awal, seluruh bobot MobileNetV2 dibekukan dan hanya lapisan klasifikasi akhir yang dilatih. Dataset telah melalui proses augmentasi dan penyeimbangan kelas untuk memastikan model belajar dari distribusi data yang proporsional.

Pada tahap pelatihan awal (*frozen base*), grafik menunjukkan kinerja yang meningkat secara signifikan setelah model CNN dengan arsitektur MobileNetV2 diterapkan dengan bobot yang dibekukan. Akurasi pada data pelatihan mengalami peningkatan konsisten dari sekitar 55% pada awal *epoch* hingga mencapai lebih dari 91% pada *epoch* ke-50. Sementara itu, akurasi validasi juga menunjukkan tren positif, meningkat stabil dari sekitar 65% hingga mencapai kisaran 93–94%. Grafik *loss* memperkuat temuan ini, dengan penurunan training loss dari sekitar 1,0 menjadi mendekati 0,2, sedangkan *validation loss* bahkan menunjukkan penurunan lebih signifikan dari 0,6 ke sekitar 0,2. Pola ini mencerminkan proses pelatihan yang stabil tanpa indikasi *overfitting*, ditunjukkan oleh *validation loss* yang tetap lebih rendah dan stabil dibandingkan *training loss*. Secara keseluruhan, tahap *frozen base* berhasil membentuk dasar model yang kuat dan layak dilanjutkan ke proses *fine-tuning* untuk

mengoptimalkan performa secara menyeluruh. Tahapan awal ini dapat dilihat pada Gambar 5 yang merupakan grafik *training* validasi akurasi dan *loss* validasi *frozen base*.



**Gambar 5** Grafik *training validation accuracy* dan *validation loss frozen base*

Selanjutnya, hasil dari *classification report* setelah *training* awal yang menunjukkan bahwa model memiliki performa awal yang baik dengan akurasi keseluruhan 93%. Nilai *F1-score* untuk kelas rendah dan sedang sebesar 0,92, serta kelas tinggi sebesar 0,96, menandakan klasifikasi yang seimbang. *Classification report* setelah *training* awal dapat dilihat pada Tabel 4.

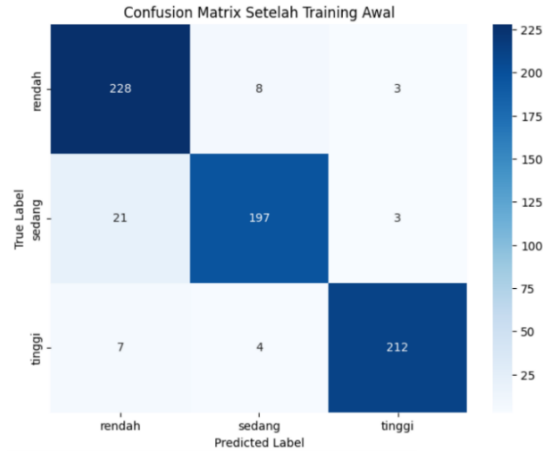
**Tabel 4** *Classification report* setelah *training* awal

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Rendah	0,89	0,95	0,92	239
Sedang	0,94	0,89	0,92	221
Tinggi	0,97	0,95	0,96	223
<b><i>Accuracy</i></b>			<b>0,93</b>	683
<i>Macro avg</i>	0,94	0,93	0,93	683
<i>Weighted avg</i>	0,93	0,93	0,93	683

Pada tahap selanjutnya, hasil evaluasi menunjukkan bahwa model mampu melakukan prediksi dengan tingkat akurasi yang tinggi, terutama pada kelas rendah dengan jumlah prediksi benar sebanyak 228 citra. Jumlah kesalahan klasifikasi yang relatif kecil mengindikasikan bahwa model sudah cukup andal dalam membedakan kualitas sarang burung walet. Informasi lebih lanjut terkait performa ini dapat dilihat pada Tabel 5 dan Gambar 6, yang menampilkan *confusion matrix* setelah pelatihan awal dengan kondisi *frozen base*.

**Tabel 5** *Confusion matrix* setelah *training* awal

<i>True</i>	<i>Predicted</i>		
	Rendah	Sedang	Tinggi
Rendah	228	8	3
Sedang	21	197	3
Tinggi	7	4	212



Gambar 6 Confusion matrix setelah training awal

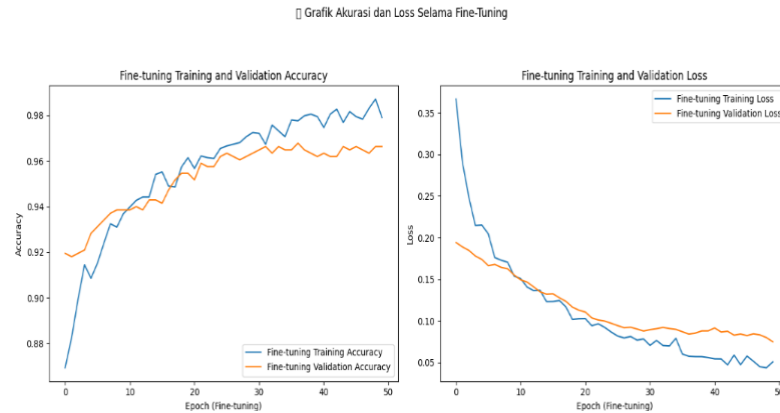
Hasil evaluasi pada tahap pelatihan awal menunjukkan bahwa model telah mampu mengklasifikasikan citra dengan cukup baik, dengan akurasi mencapai 93%. Namun, masih terdapat beberapa kesalahan klasifikasi antar kelas, khususnya antara kelas sedang dan rendah. Hal ini menjadi dasar perlunya dilakukan *fine-tuning* untuk meningkatkan performa model.

Pada tahap *fine-tuning*, beberapa lapisan awal dari arsitektur MobileNetV2 dibuka dan dilibatkan kembali dalam proses pelatihan. Langkah ini dilakukan untuk mengoptimalkan penyesuaian bobot model terhadap karakteristik spesifik dari citra sarang burung walet, yang sebelumnya belum sepenuhnya ditangkap selama tahap pelatihan awal.

Hasil pelatihan menunjukkan adanya peningkatan performa yang signifikan. Akurasi pelatihan terus meningkat secara konsisten hingga mendekati 99%, sedangkan akurasi validasi tetap stabil di atas 96%. Hal ini menandakan bahwa model mengalami peningkatan kemampuan dalam mengenali pola citra tanpa mengalami *overfitting* yang berarti. Di sisi lain, grafik nilai *loss* pada data pelatihan dan validasi menunjukkan tren penurunan yang konsisten, dengan *loss* validasi bertahan rendah di bawah 0,10 hingga akhir pelatihan. Pola ini menunjukkan bahwa proses *fine-tuning* mampu meningkatkan generalisasi model secara efektif. Grafik *training validation* akurasi dan *validation loss* selama *fine-tuning* dapat dilihat pada Gambar 7.

Setelah dilakukan *fine-tuning* pada model CNN, performa klasifikasi meningkat secara signifikan dengan akurasi keseluruhan mencapai 97%. Hal ini tercermin dari nilai *precision*, *recall*, dan *F1-score* yang tinggi pada seluruh kelas. Kelas tinggi menunjukkan hasil sempurna dengan nilai *precision*, *recall*, dan *F1-score* sebesar 1,00. Sementara itu, kelas rendah dan sedang masing-masing memperoleh *F1-score* sebesar 0,95. Rata-rata makro dan rata-rata tertimbang juga menunjukkan konsistensi performa model dengan nilai 0,97, seperti ditunjukkan pada Tabel 6.

Selanjutnya Tabel 7 dan Gambar 8 menunjukkan *confusion matrix* setelah *fine-tuning* hasil pengujian model terhadap data validasi, yang menggambarkan jumlah prediksi benar dan salah untuk tiap kelas.




**Gambar 7** Grafik *training validation* akurasi dan *validation loss* selama *fine-tuning*

**Tabel 6** *Classification report* setelah *fine-tuning*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Rendah	0,94	0,97	0,95	239
Sedang	0,97	0,93	0,95	221
Tinggi	1,00	1,00	1,00	223
<b><i>Accuracy</i></b>			<b>0,97</b>	683
<i>Marco avg</i>	0,97	0,97	0,97	683
<i>Weighted avg</i>	0,97	0,97	0,97	683

**Tabel 7** *Confusion matrix* setelah *fine-tuning*

<i>True</i>	<i>Predicted</i>		
	Rendah	Sedang	Tinggi
Rendah	232	6	1
Sedang	15	206	0
Tinggi	0	0	223



**Gambar 8** *Confusion matrix* setelah *fine-tuning*

Tabel 7 dan Gambar 8 menyajikan hasil evaluasi performa model berdasarkan akurasi, *precision*, *recall*, dan *F1-score* untuk tiap kelas kualitas sarang burung walet. Setelah proses *fine-tuning*, akurasi validasi meningkat dari 93% menjadi 97%, dengan rata-rata *precision*, *recall*, dan *F1-score* sebesar 0,97. Peningkatan ini menunjukkan bahwa *fine-tuning* efektif dalam menyesuaikan bobot *pretrained* terhadap karakteristik citra lokal, serta meningkatkan generalisasi model.

Model menunjukkan performa klasifikasi yang seimbang antar kelas (tinggi, sedang, dan rendah), dengan kestabilan *F1-score* di seluruh kelas. Hal ini menegaskan bahwa arsitektur CNN berbasis MobileNetV2 layak diimplementasikan sebagai sistem klasifikasi otomatis yang efisien dan objektif dalam industri sarang burung walet. Perbandingan performa sebelum dan sesudah *fine-tuning* dapat dilihat pada Tabel 8.

**Tabel 8** Perbandingan sebelum dan sesudah *fine-tuning*

Metode	Akurasi	F1-Score Tertinggi	Kesalahan Terbanyak
Sebelum	93%	Tinggi (0,96)	Sedang, Rendah (15x)
Setelah	97%	Tinggi (0,98)	Rendah, Sedang (6x)

Beberapa penelitian sebelumnya telah dilakukan untuk mengklasifikasikan kualitas atau karakteristik sarang burung walet. Penelitian [4] menggunakan fitur bentuk dan SVM, mencapai akurasi 89,3%. Penelitian [5] memanfaatkan SSD-MobileNetV2 untuk mendeteksi bentuk sarang, namun hanya memperoleh mAP sebesar 61,91%. Penelitian [6] menggunakan metode Fuzzy Tsukamoto dengan lima parameter dan mencapai akurasi 97% pada 100 data uji. Sementara itu, Jayadi (2024) mengembangkan sistem klasifikasi kebersihan sarang dengan Random Forest dan SVM, di mana *Random Forest* mencapai akurasi tertinggi 97,5%.

Berbeda dari pendekatan sebelumnya yang mengandalkan fitur buatan (*handcrafted*) atau parameter manual, penelitian ini menggunakan CNN berbasis transfer learning MobileNetV2 secara end-to-end. Citra sarang diproses langsung melalui penghapusan latar belakang dan augmentasi visual, tanpa ekstraksi fitur manual. Dengan pendekatan ini, model mampu mengenali pola kompleks secara otomatis dari gambar mentah dan mencapai akurasi validasi 97%, menunjukkan keunggulan CNN dalam klasifikasi visual berbasis data riil.

Meskipun model CNN yang dikembangkan menunjukkan performa klasifikasi yang sangat baik, penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Seluruh data citra sarang burung walet diperoleh dari satu petani di Provinsi Sulawesi Tengah, yang dapat menyebabkan homogenitas karakteristik visual dan membatasi kemampuan generalisasi model terhadap data dari daerah atau sumber lain. Pemanfaatan data dari satu sumber dilakukan karena keterbatasan akses terhadap petani lain, serta keterbatasan logistik, waktu, dan sumber daya dalam ruang lingkup penelitian ini. Selain itu, variasi pencahayaan alami saat pengambilan gambar tetap

berpotensi memengaruhi kualitas citra dan akurasi klasifikasi, meskipun telah dilakukan penghapusan latar belakang untuk mengurangi gangguan visual.

Upaya normalisasi pencahayaan belum dilakukan secara sistematis karena fokus utama penelitian ini adalah pada struktur visual sarang, bukan pada kondisi pencahayaan. Evaluasi model juga hanya dilakukan satu kali dengan menggunakan pembagian data 80:20 tanpa menerapkan teknik validasi silang seperti *k-fold cross-validation*, sehingga hasil evaluasi belum sepenuhnya mencerminkan kemampuan generalisasi model. Pemilihan metode evaluasi ini dilakukan karena keterbatasan waktu komputasi serta fokus penelitian yang diarahkan pada pengujian arsitektur CNN dengan dataset terbatas. Selain itu, penelitian ini belum menyertakan visualisasi interpretatif seperti Grad-CAM, karena prioritas diarahkan pada pencapaian akurasi model.

### Simpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model klasifikasi kualitas sarang burung walet berbasis CNN dengan pendekatan transfer learning menggunakan arsitektur MobileNetV2 berhasil dikembangkan secara efektif. Dataset terdiri dari 3.406 citra hasil augmentasi dan penghapusan latar belakang, yang dibagi menjadi 2.723 citra untuk pelatihan dan 683 untuk validasi, mencakup tiga kelas kualitas. Model dilatih melalui dua tahap, yaitu pelatihan awal (*frozen base*) dan pelatihan lanjutan (*fine-tuning*). Hasil evaluasi menunjukkan peningkatan akurasi validasi dari 93% menjadi 97% setelah *fine-tuning*. Nilai *precision*, *recall*, dan *F1-score* rata-rata sebesar 0,97 menunjukkan performa klasifikasi yang konsisten dan seimbang. Temuan ini menunjukkan bahwa strategi *transfer learning* dengan *fine-tuning* efektif dalam menyesuaikan bobot model terhadap domain data spesifik, serta dapat digunakan untuk klasifikasi kualitas sarang burung walet secara objektif dan efisien.

Penelitian ini memiliki keterbatasan pada keterwakilan data yang hanya berasal dari satu petani di Sulawesi Tengah serta tidak menggunakan validasi silang. Oleh karena itu, penelitian lanjutan disarankan untuk memperluas cakupan data dari berbagai daerah, menerapkan validasi silang (*k-fold cross-validation*), dan menambahkan interpretasi visual seperti Grad-CAM guna memahami fitur penting dalam proses klasifikasi.

### Daftar Pustaka

- [1] M. Wandha Chayaning and I. Anshori, "Strategi Pemasaran Sarang Burung Walet di Lamongan Melalui Karakteristik Kerja," *J. Bisnis Terap.*, vol. 6, no. 1, pp. 53–62, 2022, doi: 10.24123/jbt.v6i1.4821.
- [2] T. H. Lee, J. R. Chen, and C. Y. Lin, "Structural Composition and Bioactivity of

- 
- Edible Bird's Nest," *J. Food Drug Anal.*, vol. 29, no. 3, pp. 439–450, 2021, doi: 10.38212/2224.
- [3] Y. Zhang, Q. Li, and X. Chen, "Characterization of Glycoproteins and Bioactive Properties of Edible Bird's Nest," *Food Chem.*, vol. 375, p. 131897, 2022, doi: 10.1016/j.foodchem.2021.131897.
- [4] A. Septiarini, "Classifying the Swallow Nest Quality Using Support Vector Machine Based on Computer Vision," in *2022 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*, 2022, pp. 474–478. doi: 10.1109/CYBERNETICSCOM55287.2023.9865498.
- [5] D. I. Jaya, "Object Detection to Identify Shapes of Swallow Nests Using a Deep Learning Algorithm," *J. Theor. Appl. Inf. Technol.*, vol. 8, no. 1, pp. 139–148, 2022.
- [6] E. Fahrul Agus, E. Sulfika, and G. Mahendra Putra, "Analisis Kualitas Sarang Burung Walet Menggunakan Metode Fuzzy Tsukamoto," *J. Teknol. Inf. dan Ilmu Komput. (JTIK)*, vol. 12, no. 2, pp. 391–398, 2025, doi: 10.25126/jtiik.2025129441.
- [7] A. A. Elngar, "Image Classification Based on CNN: A Survey," *J. Cybersecurity Inf. Manag. (JCIM)*, vol. 6, no. 1, pp. 18–50, 2021, doi: 10.5281/zenodo.4897990.
- [8] Q. Zheng, M. Yang, X. Tian, N. Jiang, and D. Wang, "A full stage data augmentation method in deep convolutional neural network for natural image classification," *Discret. Dyn. Nat. Soc.*, vol. 2020, p. 11, 2020.
- [9] J. Yoo and S. Kang, *Class-Adaptive Data Augmentation for Image Classification*. IEEE Access, 2023. doi: 10.1109/ACCESS.2023.3258179.
- [10] M. J. Jayadi, "Classification of Swallow Nest Quality Based on Cleanliness Level Using Computer Vision," in *International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2024, pp. 477–482. doi: 10.1109/ICIMCIS63449.2024.10957480.
- [11] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. Big Data*, vol. 8, no. 1, pp. 1–48, 2021.
- [12] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of Convolutional Neural Network (CNN)," in *Proceedings of the 2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6. doi: 10.1109/ICEngTechnol.2017.8308186.
- [13] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of Convolutional Neural Network in Deep Learning," *Int. J. Eng. Technol.*, vol. 12, no. 2, pp. 130–138, 2023, doi: 10.14419/ijet.v12i2.12345.

- 
- [14] R. Patel and S. Patel, "A comprehensive study of applying convolutional neural network for computer vision," *Int. J. Adv. Sci. Technol*, vol. 29, no. 6s, pp. 2161–2174, 2020.
- [15] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, p. 6, 2020, doi: 10.1186/s12864-019-6413-7.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.