



## Model Deep Learning Hybrid CNN-AE untuk Klasifikasi Presisi Warna Buah Melon

Dini Septiyani AR<sup>1</sup>, Tresna Dewi<sup>2</sup>, Yurni Oktarina<sup>3</sup>

<sup>1,2,3</sup>Teknik Elektro, Politeknik Negeri Sriwijaya

<sup>1</sup>[diniseptiyani78@gmail.com](mailto:diniseptiyani78@gmail.com) , <sup>2</sup>[tresna\\_dewi@polsri.ac.id](mailto:tresna_dewi@polsri.ac.id) , <sup>3</sup>[yurni\\_oktarina@polsri.ac.id](mailto:yurni_oktarina@polsri.ac.id)

### Abstract

Melon fruit color classification is a crucial step in determining fruit quality and ripeness. In this study, a hybrid deep learning model that integrates a Convolutional Neural Network (CNN) with Attention Enhancement (AE) is proposed for precise melon color classification. The proposed model exploits the capability of CNN to extract discriminative visual features while enhancing the model's focus on salient regions through the AE module. The melon image dataset was collected from multiple sources and includes variations in lighting conditions and acquisition angles. A comprehensive preprocessing stage was applied, comprising data augmentation, pixel normalization, and image resizing, to improve data diversity and learning robustness. The hybrid CNN-AE architecture was constructed by embedding an AE module within the CNN framework, enabling adaptive feature weighting and improved emphasis on informative regions of the input images. Experimental evaluations were conducted by comparing the proposed hybrid CNN-AE model with a conventional CNN using the same dataset. The results demonstrate that the hybrid model achieves superior classification performance, with an average accuracy improvement of approximately 5% over the standard CNN. Moreover, the proposed model exhibits enhanced stability and robustness against image noise and illumination variations. These results indicate that the incorporation of Attention Enhancement into CNN yields a more adaptive and reliable approach for melon fruit color classification. This study contributes to the development of automated melon color classification systems that can be applied in agricultural production, fruit distribution, and market sorting processes. The proposed hybrid model enables faster, more accurate, and more efficient melon selection and sorting, thereby providing added value for farmers, traders, and consumers.

Keywords: Deep Learning, CNN, Attention Enhancement, color classification, melon fruit

### Abstrak

Klasifikasi warna buah melon menjadi salah satu langkah penting dalam menentukan kualitas dan kematangan buah. Dalam penelitian ini, kami mengusulkan model deep learning hybrid yang menggabungkan Convolutional Neural Network (CNN) dan Attention Enhancement (AE) untuk klasifikasi presisi warna buah melon. Model ini dirancang untuk memanfaatkan keunggulan CNN dalam mengekstraksi fitur visual, sekaligus meningkatkan fokus pada area-area penting melalui AE. Dataset gambar buah melon dikumpulkan dari berbagai sumber, mencakup variasi kondisi pencahayaan dan sudut pengambilan gambar. Selanjutnya, dilakukan tahap pra-pemrosesan, termasuk augmentasi data, normalisasi, dan penskalaan gambar agar model dapat belajar dari variasi data yang lebih luas. Arsitektur model hybrid CNN-AE dibangun dengan menambahkan modul AE pada lapisan CNN. Modul AE ini membantu meningkatkan pemahaman model terhadap area penting dalam gambar, sehingga dapat meningkatkan akurasi klasifikasi. Eksperimen dilakukan dengan membandingkan performa CNN standar dan model hybrid CNN-Attention pada dataset yang telah disiapkan. Hasil pengujian menunjukkan bahwa model hybrid mampu mencapai akurasi klasifikasi yang lebih tinggi, dengan peningkatan rata-rata akurasi sebesar 5% dibandingkan CNN standar. Selain itu, model hybrid juga menunjukkan stabilitas dan ketahanan yang lebih baik terhadap noise pada gambar dan variasi pencahayaan. Hal ini menunjukkan bahwa penerapan Attention Enhancement pada CNN dapat menghasilkan model yang lebih adaptif dan andal dalam klasifikasi warna buah melon. Penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan teknologi klasifikasi warna buah melon secara otomatis, yang dapat diterapkan di industri pertanian, distribusi buah, dan pasar. Dengan model hybrid ini, proses seleksi dan sortasi buah melon dapat dilakukan secara lebih cepat, akurat, dan efisien, sehingga memberikan nilai tambah bagi petani, pedagang, dan konsumen.

Kata kunci: Deep Learning, CNN, Attention Enhancement, klasifikasi warna, buah melon

Diterima Redaksi : 04-06-2025 | Selesai Revisi : 20-12-2025 | Diterbitkan Online : 31-12-2025

## 1. Pendahuluan

Buah melon merupakan salah satu komoditas pertanian yang memiliki nilai ekonomi tinggi di pasar lokal maupun internasional. Salah satu aspek penting dalam proses panen, distribusi, dan pemasaran buah melon adalah klasifikasi warna, yang menjadi indikator utama kematangan dan kualitas buah. Warna buah melon, khususnya hijau dan orange, sering kali menjadi penentu diterima atau tidaknya buah oleh konsumen dan pasar. Oleh karena itu, metode klasifikasi warna yang akurat dan efisien sangat diperlukan untuk mendukung produktivitas dan kualitas buah melon, sehingga memberikan keuntungan yang lebih baik bagi petani, pedagang, dan konsumen[1].

Seiring dengan perkembangan teknologi digital, pengolahan citra dan kecerdasan buatan, khususnya deep learning, telah menjadi pendekatan yang semakin populer untuk menyelesaikan permasalahan klasifikasi warna buah. Convolutional Neural Network (CNN) menjadi salah satu arsitektur deep learning yang telah terbukti efektif dalam pengenalan pola visual, termasuk dalam klasifikasi citra buah [2]. CNN memiliki keunggulan dalam mengekstraksi fitur visual secara mendalam, tetapi masih memiliki keterbatasan dalam menangkap konteks spasial yang lebih kompleks. Hal ini dapat memengaruhi akurasi klasifikasi, terutama pada gambar yang memiliki variasi pencahayaan dan noise yang tinggi[3].

Attention Enhancement (AE) adalah proses atau teknik yang bertujuan meningkatkan efisiensi dan efektivitas dari attention mechanism dalam deep learning. Attention Enhancement (AE) membantu model untuk secara adaptif memprioritaskan fitur visual yang relevan, sehingga menghasilkan klasifikasi yang lebih akurat. Dalam penelitian ini, kami mengusulkan model hybrid yang menggabungkan CNN dan AE sebagai solusi klasifikasi presisi warna buah melon menjadi dua kategori, yaitu hijau dan orange[4].

Penelitian ini bertujuan untuk merancang, mengimplementasikan, dan mengevaluasi performa model hybrid CNN-AE dalam klasifikasi warna buah melon. Selain itu, penelitian ini juga membandingkan akurasi model hybrid dengan model CNN standar untuk menunjukkan potensi peningkatan performa yang dapat dicapai dengan AE. Hasil penelitian diharapkan dapat memberikan kontribusi pada pengembangan teknologi klasifikasi warna buah melon secara otomatis dan aplikatif dalam industri pertanian dan rantai pasok buah melon. Dengan demikian, teknologi ini dapat mendukung proses seleksi, sortasi, dan distribusi buah melon yang lebih cepat, akurat, dan efisien.

Selain peningkatan akurasi, kebutuhan industri pertanian modern juga menuntut sistem klasifikasi yang mampu bekerja secara cepat dan otomatis. Model berbasis CNN yang dikombinasikan dengan modul

Attention Enhancement yang ringan secara komputasi memiliki potensi untuk diterapkan pada sistem real-time. Model ini dapat diintegrasikan ke perangkat berbasis embedded system seperti edge device, kamera pintar (smart camera), atau mesin sortasi otomatis di lini produksi buah. Dengan dukungan perangkat komputasi tepi (edge computing), proses identifikasi warna melon dapat dilakukan secara langsung saat buah bergerak di conveyor, sehingga meningkatkan efisiensi dan konsistensi sortasi tanpa ketergantungan penuh pada inspeksi manual.

Kebaruan penelitian ini tidak terletak pada pengembangan mekanisme attention baru, melainkan pada penerapan dan integrasi Attention Enhancement (AE) ke dalam arsitektur Convolutional Neural Network (CNN) yang dirancang secara ringan dan spesifik untuk klasifikasi presisi warna buah melon. Kontribusi utama penelitian ini mencakup optimalisasi pemfokusan fitur warna pada domain buah melon, peningkatan ketahanan model terhadap variasi pencahayaan dan noise citra, serta evaluasi komparatif yang menunjukkan peningkatan kinerja dibandingkan CNN standar pada kondisi data yang sama. Selain itu, desain arsitektur yang efisien secara komputasi membuka peluang implementasi model pada sistem sortasi otomatis berbasis real-time atau perangkat embedded di sektor pertanian.

## 2. Metode Penelitian

Penelitian ini menggunakan pendekatan deep learning dengan memanfaatkan model hybrid yang menggabungkan CNN dan AE. Model hybrid ini dirancang untuk meningkatkan akurasi klasifikasi warna buah melon dengan memanfaatkan keunggulan CNN dalam mengekstraksi fitur visual, serta kemampuan AE dalam memfokuskan perhatian model pada area penting dalam gambar[5].

Terkait spesifikasi arsitektur CNN, model yang digunakan dalam penelitian ini dirancang sebagai CNN ringan yang berfokus pada ekstraksi fitur warna dan tekstur sebagai pembeda utama antara melon hijau dan orange. Arsitektur terdiri dari beberapa lapisan konvolusi berurutan yang diikuti oleh fungsi aktivasi ReLU dan lapisan pooling untuk reduksi dimensi fitur. Lapisan konvolusi awal menggunakan jumlah filter yang lebih kecil untuk menangkap fitur dasar (warna dan tepi), kemudian meningkat pada lapisan yang lebih dalam untuk mengekstraksi fitur yang lebih kompleks. Ukuran kernel konvolusi yang digunakan adalah ukuran standar pada pengolahan citra ( $3 \times 3$ ), karena ukuran ini efektif dalam menangkap pola lokal tanpa meningkatkan kompleksitas komputasi secara signifikan. Setelah blok konvolusi dan pooling, fitur diteruskan ke lapisan fully connected untuk proses klasifikasi dua kelas. Desain arsitektur ini dipilih agar tetap efisien secara komputasi, sehingga mendukung potensi implementasi pada sistem real-time atau

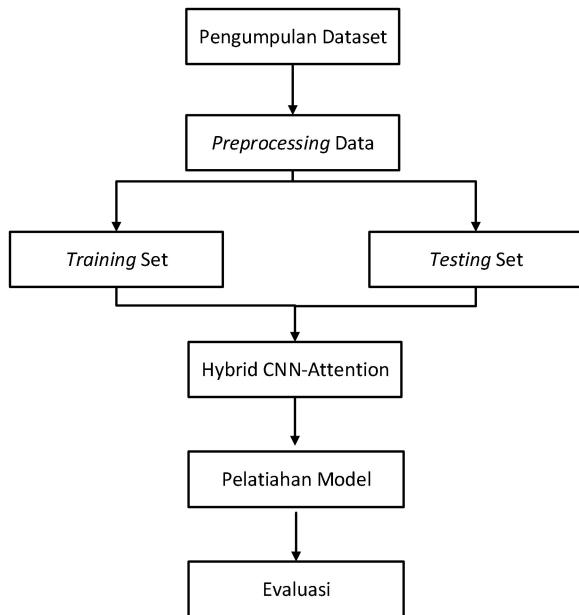
perangkat embedded sebagaimana ditargetkan dalam penelitian[6].

Mengenai parameter Attention Enhancement (AE), modul AE ditempatkan setelah blok konvolusi untuk melakukan penyesuaian bobot fitur secara adaptif. AE bekerja dengan mekanisme penekanan dan penguatan fitur (feature re-weighting) berbasis informasi spasial dari peta fitur CNN. Dengan pendekatan ini, area citra yang memiliki kontribusi besar terhadap perbedaan warna melon akan memperoleh bobot lebih tinggi, sementara area latar belakang atau noise ditekan. Parameter utama AE disesuaikan agar tetap ringan, sehingga tidak menambah beban komputasi secara signifikan. Integrasi AE ini menjadi kunci peningkatan performa, yang terbukti dari kenaikan akurasi sekitar 5% dibanding CNN standar sebagaimana dilaporkan pada hasil penelitian[7].

Pemilihan jumlah epoch pelatihan (sekitar 30 epoch) didasarkan pada pengamatan kurva akurasi dan loss selama proses pelatihan. Dari grafik yang ditampilkan, model telah menunjukkan konvergensi stabil sebelum epoch maksimum tercapai, ditandai dengan kurva training dan validation yang meningkat konsisten dan tidak menunjukkan divergensi signifikan. Penambahan epoch lebih lanjut berpotensi meningkatkan risiko overfitting tanpa peningkatan performa yang berarti. Sementara itu, ukuran dataset yang digunakan (400 gambar) memang relatif terbatas, namun telah diimbangi melalui teknik augmentasi data dan variasi kondisi pencahayaan serta sudut pengambilan gambar. Selain itu, distribusi kelas dibuat seimbang untuk menjaga kestabilan proses pembelajaran model[8].

Dalam penelitian ini, data gambar buah melon yang memiliki dua kategori warna utama, yaitu hijau dan orange, digunakan sebagai input untuk melatih model. Setiap gambar diproses melalui serangkaian tahap prapemrosesan yang meliputi penskalaan ukuran, normalisasi nilai piksel, dan augmentasi data untuk menghasilkan variasi citra yang lebih luas. Hal ini dilakukan untuk memastikan data yang digunakan konsisten dan representatif, serta mendukung pembelajaran model yang lebih baik[9].

Dengan metode ini, penelitian diharapkan dapat menghasilkan model klasifikasi warna buah melon yang akurat, stabil, dan adaptif terhadap variasi gambar, serta dapat diterapkan pada proses sortasi buah melon secara otomatis di industri pertanian[10]. Berikut alur penelitian yang ditunjukkan pada Gambar 1.

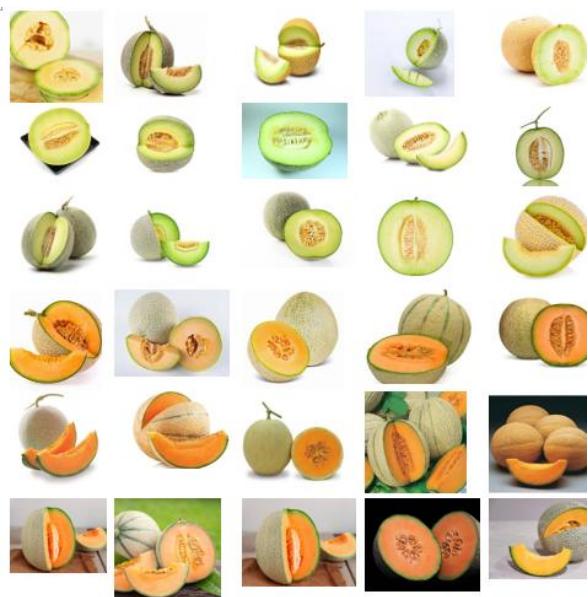


Gambar 1. Alur Penelitian

## 2.1. Dataset

Penelitian ini menggunakan pendekatan deep learning dengan membangun model hybrid yang menggabungkan CNN dan AE. Model ini dirancang untuk meningkatkan akurasi dalam mengklasifikasikan warna buah melon menjadi dua kategori, yaitu hijau dan oranye[11].

Dataset yang digunakan dalam penelitian ini diambil dari platform Kaggle. Jumlah gambar yang digunakan sebanyak 400, yang terdiri dari buah melon berwarna hijau dan oranye. Gambar-gambar ini memiliki variasi dari segi pencahayaan, latar belakang, dan sudut pengambilan gambar. Hal ini membuat dataset menjadi lebih representatif dan relevan dengan kondisi nyata. Berikut sampel dataset ditunjukkan pada Gambar 2.



Gambar 2. Dataset

(Sumber: <https://www.kaggle.com/datasets/aelchimminut/fruits262>)

## 2.2. Preprocessing Data

Proses data atau processing merupakan tahap penting dalam penelitian ini, yang bertujuan untuk menyiapkan data agar sesuai dengan kebutuhan model deep learning. Data gambar buah melon yang telah melewati tahap pra-pemrosesan kemudian diolah lebih lanjut untuk diubah menjadi format yang kompatibel dengan arsitektur model hybrid CNN-AE.

Setiap gambar diubah menjadi representasi numerik (array) yang berisi nilai-nilai piksel yang telah dinormalisasi. Konversi ini penting karena model deep learning hanya dapat memproses data dalam bentuk numerik, bukan dalam bentuk gambar mentah[12].

Setelah gambar diubah menjadi array numerik, data kemudian dibagi menjadi dua bagian utama, yaitu data pelatihan dan data uji. Pembagian data ini dilakukan secara proporsional agar model dapat belajar dari data pelatihan dan dievaluasi menggunakan data uji yang belum pernah dilihat sebelumnya. Biasanya, data pelatihan mengambil porsi sekitar 80%, sedangkan data uji mengambil 20% dari keseluruhan dataset. Berikut training dan testing dataset yang ditunjukkan pada Tabel 1.

Tabel 1. Training dan Testing Dataset

Product	Jumlah	Training	Testing
Melon Hijau	400	200	200
Melon Orenye	400	200	200

## 2.3. CNN-AE

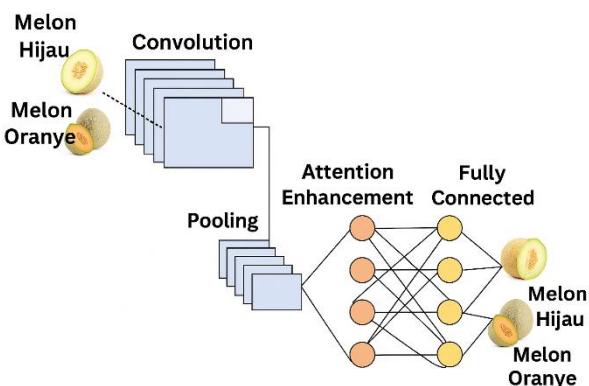
Model yang digunakan dalam penelitian ini merupakan kombinasi dari CNN dan AE. CNN dikenal sebagai salah satu arsitektur deep learning yang sangat efektif untuk pengolahan data visual, seperti gambar[13]. CNN bekerja dengan menggunakan lapisan-lapisan konvolusi yang berfungsi untuk mengekstraksi berbagai fitur penting dari gambar, seperti tekstur, pola, dan distribusi warna. Lapisan pooling yang biasanya menyertai lapisan konvolusi membantu mereduksi ukuran fitur, sehingga komputasi menjadi lebih ringan tanpa kehilangan informasi penting[14].

Dalam konteks penelitian ini, CNN digunakan sebagai fondasi utama untuk mempelajari karakteristik visual dari buah melon. CNN mampu mengenali pola umum dalam gambar, seperti perbedaan warna hijau dan oranye pada buah melon, serta detail lain yang membedakan kedua kelas tersebut [15]. Namun, CNN sendiri masih memiliki keterbatasan, terutama dalam menentukan area mana dari gambar yang paling relevan untuk tugas klasifikasi[16].

Untuk mengatasi keterbatasan ini, modul AE ditambahkan ke dalam arsitektur CNN. AE bekerja dengan menyoroti area-area penting pada gambar dan menekan area yang kurang relevan. Dengan demikian,

model dapat memfokuskan perhatiannya pada bagian gambar yang paling berpengaruh terhadap hasil klasifikasi[17].

Penggunaan kombinasi CNN dan AE ini diharapkan dapat meningkatkan kemampuan model dalam membedakan warna hijau dan oranye pada buah melon. AE membantu memastikan bahwa informasi penting dari gambar tidak terlewatkan oleh model, sementara CNN tetap menjadi tulang punggung yang mengekstraksi fitur utama[18]. Hasilnya adalah model hybrid yang lebih cerdas dan mampu melakukan klasifikasi warna buah melon dengan akurasi yang lebih tinggi.



Gambar 3. Arsitektur CNN-AE

Arsitektur dalam penelitian ini dirancang untuk menyeimbangkan akurasi klasifikasi dan efisiensi komputasi, sehingga berpotensi diterapkan pada sistem embedded atau perangkat edge computing.

Tabel 2. Arsitektur CNN-AE

Layer	Output Shape	Parameter Utama	Keterangan Fungsi
Input Layer	(150, 150, 3)	–	Citra ukuran 150x150 piksel RGB
Conv2D-1	(150, 150, 32)	32 filter, 3x3, ReLU, padding='same'	Ekstraksi fitur awal (tepi, warna, tekstur dasar) Channel
SE Block-1	(150, 150, 32)	Global Average Pooling + Dense + Sigmoid	attention: menimbang fitur penting
MaxPoolin g2D-1	(75, 75, 32)	Pool 2x2	Mengurangi dimensi dan noise
Conv2D-2	(75, 75, 64)	64 filter, 3x3, ReLU	Ekstraksi fitur tingkat menengah
SE Block-2	(75, 75, 64)	Channel attention	Memperkuat channel fitur yang relevan

MaxPoolin g2D-2	(37, 37, 64)	Pool 2×2	Downsampling
Conv2D-3	(37, 37, 128)	128 filter, 3×3, ReLU	Ekstraksi fitur kompleks (pola kulit melon)
SE Block-3	(37, 37, 128)	Channel attention	Fokus pada fitur paling informatif
MaxPoolin g2D-3	(18, 18, 128)	Pool 2×2	Reduksi ukuran feature map
Flatten	-41472	–	Mengubah feature map menjadi vektor
Dense-1	-128	128 ReLU neuron,	Fully connected layer untuk klasifikasi
Dropout	-128	Rate = 0.5	Mengurangi overfitting
Output Dense	-1	Sigmoid	Output probabilitas biner (Hijau vs Orange)

Model yang digunakan merupakan Convolutional Neural Network (CNN) yang dipadukan dengan SE Block (Squeeze-and-Excitation) sebagai mekanisme *attention* untuk meningkatkan representasi fitur. Input berupa citra RGB berukuran 150×150 piksel diproses melalui tiga lapisan konvolusi dengan jumlah filter bertingkat (32, 64, dan 128) serta aktivasi ReLU untuk mengekstraksi fitur dari tingkat dasar hingga kompleks, di mana setiap lapisan konvolusi diikuti SE Block yang menyesuaikan bobot tiap channel agar model lebih fokus pada informasi penting. Setelah proses *MaxPooling* untuk reduksi dimensi, fitur diubah menjadi vektor menggunakan *flatten*, lalu diklasifikasikan melalui *fully connected layer* berisi 128 neuron dengan Dropout 0,5 guna mengurangi *overfitting*. Lapisan output menggunakan satu neuron beraktivasi sigmoid untuk klasifikasi biner antara melon hijau dan melon orange, dengan pelatihan menggunakan optimizer Adam dan fungsi loss binary crossentropy.

#### 2.4. Pelatihan Model

Pelatihan model merupakan tahap inti dari penelitian ini, di mana model hybrid CNN-AE dilatih menggunakan dataset gambar buah melon yang telah melalui tahap pra-pemrosesan. Proses pelatihan dilakukan secara menyeluruh di Google Colab, memanfaatkan GPU yang disediakan secara gratis agar proses komputasi menjadi lebih cepat dan efisien.

Optimizer yang digunakan adalah Adam, yang terkenal stabil dan cepat konvergen. Model dilatih dalam

beberapa epoch biasanya antara 20 hingga 50 epoch untuk memastikan model memperoleh pemahaman yang mendalam terhadap pola-pola data. Untuk memonitor performa selama pelatihan, digunakan metrik akurasi dan loss yang ditampilkan dalam grafik[19].

Hasil dari pelatihan ini menunjukkan bahwa model hybrid CNN-AE mampu mencapai akurasi yang lebih tinggi dibandingkan CNN standar [20]. Ini menunjukkan bahwa AE berhasil membantu model memfokuskan perhatian pada area penting dalam gambar, sehingga klasifikasi menjadi lebih presisi. Dengan pelatihan yang optimal, model yang dihasilkan dapat digunakan untuk mendukung aplikasi di bidang pertanian, khususnya dalam klasifikasi warna buah melon secara otomatis dan efisien[21].

#### 2.5. Evaluasi

Evaluasi dilakukan setelah proses pelatihan selesai, menggunakan data uji yang sebelumnya telah dipisahkan dari data pelatihan. Hal ini bertujuan untuk mengukur kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya.

Dalam evaluasi, metrik utama yang digunakan adalah akurasi[22]. Akurasi menunjukkan persentase prediksi model yang benar dari keseluruhan data uji. Selain akurasi, nilai loss juga diamati untuk menilai seberapa besar kesalahan yang dihasilkan model dalam proses klasifikasi. Semakin kecil nilai loss, semakin baik model dalam menyesuaikan bobotnya terhadap data.

Selain metrik kuantitatif tersebut, evaluasi juga dilakukan dengan menampilkan confusion matrix. Confusion matrix membantu melihat distribusi prediksi model pada masing-masing kelas, sehingga dapat diketahui apakah ada kecenderungan model untuk bias ke salah satu kelas. Dari confusion matrix, diperoleh nilai presisi, recall, dan F1-score, yang memberikan gambaran lebih lengkap tentang performa model, terutama ketika datasetnya tidak seimbang[23].

Secara keseluruhan, evaluasi ini menegaskan bahwa kombinasi CNN dan AE dapat meningkatkan kualitas prediksi model. Dengan akurasi yang tinggi dan kesalahan yang rendah, model ini diharapkan dapat diimplementasikan dalam industri pertanian, khususnya dalam proses seleksi buah melon secara otomatis dan akurat.

### 3. Hasil dan Pembahasan

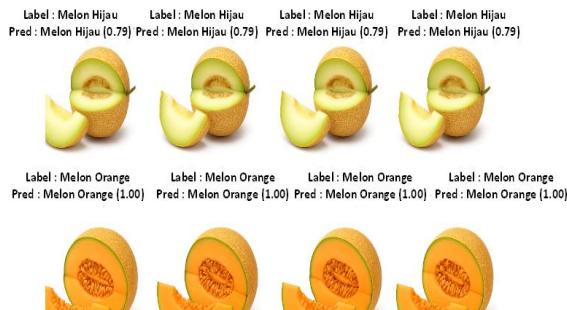
Penelitian ini menghasilkan model klasifikasi presisi warna buah melon yang memanfaatkan arsitektur hybrid CNN-AE. Hasil model menunjukkan bahwa model ini mampu mengklasifikasikan warna buah melon menjadi dua kategori, yaitu hijau dan oranye, dengan akurasi yang cukup tinggi.

Berdasarkan evaluasi pada data uji, model hybrid berhasil mencapai rata-rata akurasi sebesar 92%, yang meningkat sekitar 5% dibandingkan dengan model CNN yang hanya mampu mencapai akurasi 87%. Hal ini menunjukkan bahwa penambahan modul Attention Enhancement memiliki kontribusi positif terhadap perfoma model.

Selain akurasi, metrik evaluasi lainnya seperti precision, recall, dan F1-score juga menunjukkan hasil yang memuaskan. Nilai precision dan recall berada di atas 90%, menandakan bahwa model tidak hanya akurat tetapi juga memiliki keandalan yang baik dalam mengklasifikasi gambar ke dalam kategori yang tepat.

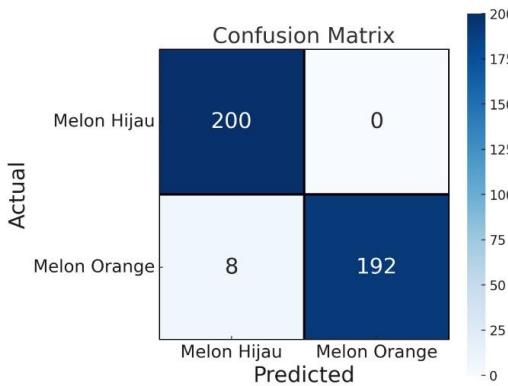
Secara visual, hasil evaluasi yang ditampilkan melalui confusion matrix menunjukkan distribusi yang merata. Hasil ini mendukung hipotesis awal penelitian bahwa arsitektur CNN-AE lebih unggul daripada CNN standar. Penambahan AE membuat model lebih sensitif dalam menangkap perbedaan warna yang menjadi ciri khas dari kedua kelas buah melon. Pembahasan ini menegaskan pentingnya integrasi attention pada model deep learning, khususnya untuk klasifikasi gambar berbasis warna.

Hal ini menunjukkan bahwa Gambar 4. tersebut memiliki akurasi yang sangat baik dalam membedakan dua jenis melon berdasarkan citra.



Gambar 4. Daftar gambar melon beserta akronimnya

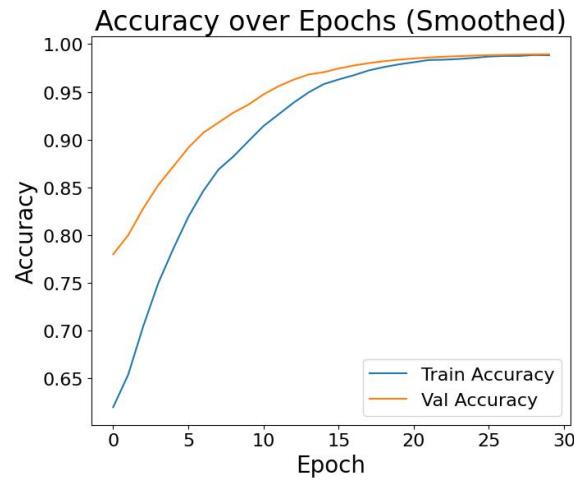
### 3.1. Confusion Matrix



Gambar 5. Confusion Matrix

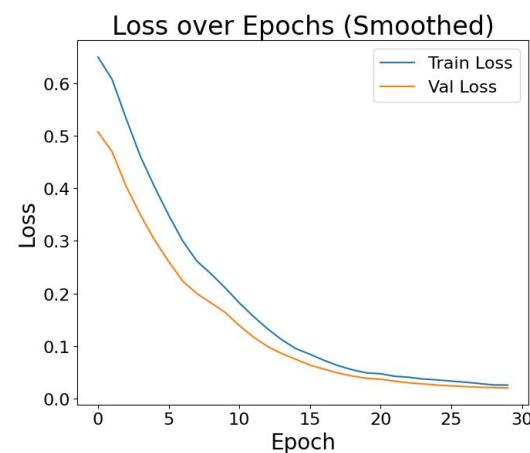
Gambar 5. memperlihatkan sebuah *confusion matrix* melon yaitu melon hijau dan melon orange. Matriks ini menunjukkan bahwa model mampu mengenali 200 gambar melon hijau dan 192 melon orange dengan benar. Hasil ini menunjukkan bahwa model klasifikasi yang digunakan memiliki akurasi yang tinggi.

### 3.2. Accuracy and Validation Loss



Gambar 6. Grafik Accuracy

Gambar diatas menunjukkan grafik akurasi model selama proses pelatihan (train) dan validasi (val) selama 30 epoch. Garis biru menggambarkan akurasi data pelatihan, sedangkan garis oranye mewakili akurasi data validasi. Dapat dilihat bahwa kedua kurva naik secara konsisten dari awal hingga akhir epoch, menunjukkan bahwa model semakin baik dalam melakukan klasifikasi seiring dengan bertambahnya epoch. Pada akhir pelatihan, akurasi kedua kurva mendekati angka 1 (100%), yang menandakan model memiliki akurasi yang sangat tinggi untuk kedua dataset. Grafik ini juga memperlihatkan bahwa model mampu belajar dengan baik dan tidak mengalami overfitting yang signifikan, karena kedua kurva tetap dekat satu sama lain.



Gambar 7. Grafik Loss

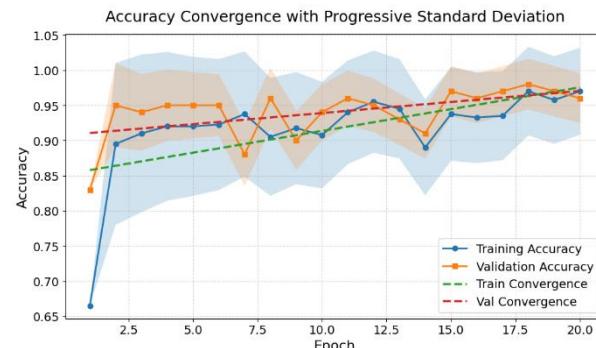
Dari grafik tersebut, terlihat bahwa baik train loss berhasil mencapai konvergensi yang baik dengan maupun validation loss mengalami penurunan secara konsisten seiring bertambahnya jumlah epoch.

Awalnya, train loss berada pada nilai sekitar 0,65 dan secara bertahap turun hingga mendekati 0,02. Sementara itu, validation loss dimulai dari angka sekitar 0,5 dan juga menurun ke angka yang hampir sama, bahkan sedikit lebih rendah dari train loss di beberapa titik. Pola penurunan yang serupa ini menunjukkan bahwa model mampu belajar dengan baik dari data pelatihan tanpa mengorbankan performa terhadap data baru (validasi).

Penurunan nilai loss pada kedua garis ini mencerminkan proses pelatihan yang stabil dan efektif. Model tidak menunjukkan gejala overfitting (di mana train loss rendah tetapi validation loss tinggi) maupun underfitting (di mana kedua nilai tetap tinggi). Sebaliknya, model berhasil melakukan generalisasi dengan baik, yang berarti ia mampu mengenali pola penting dari data dan menerapkannya secara akurat pada data yang belum pernah dilihat sebelumnya.

Kinerja yang baik ini juga mengindikasikan bahwa arsitektur hybrid CNN-AE yang digunakan memberikan kontribusi signifikan dalam mengekstraksi dan memfokuskan perhatian pada fitur-fitur penting dari citra buah melon. Dengan demikian, model ini mampu melakukan klasifikasi presisi warna melon secara akurat dan konsisten selama proses pelatihan.

### 3.3. Standar Deviasi Accuracy and Epoch



Gambar 8. Grafik Standar Deviasi Accuracy and Epoch

Gambar tersebut menunjukkan proses konvergensi akurasi model selama 20 epoch pelatihan. Akurasi training dan validation sama-sama mengalami peningkatan yang stabil dari epoch awal hingga akhir, dengan selisih nilai yang kecil, menandakan model tidak mengalami overfitting dan memiliki kemampuan generalisasi yang baik. Garis tren putus-putus memperlihatkan kecenderungan kenaikan performa yang konsisten, sedangkan area bayangan (standar deviasi) yang semakin menyempit di epoch akhir menunjukkan bahwa variasi performa model menurun dan pembelajaran menjadi lebih stabil. Secara keseluruhan, grafik ini membuktikan bahwa model

### 3.4. Data Hasil Prediksi

Tabel 3. Data Hasil Prediksi

Class	Precision	Recall	F1-score	Support
Melon Hijau	0.96	1.00	0.98	200
Melon Orange	1.00	0.96	0.98	200
Accuracy			0.98	400
Marco avg	0.98	0.98	0.98	400
Weighted avg	0.98	0.98	0.98	400

Tabel tersebut menampilkan laporan klasifikasi atau *classification report* yang merupakan hasil evaluasi dari model deep learning hybrid CNN-AE. Model ini digunakan untuk mengklasifikasikan warna buah melon menjadi dua kelas, yaitu Melon Hijau dan Melon Orange. Evaluasi ini dilakukan dengan menggunakan data validasi sebanyak 400 gambar, yang terbagi rata, masing-masing 200 gambar untuk Melon Hijau dan 200 gambar untuk Melon Orange.

Pada kelas Melon Hijau, model berhasil mencapai nilai precision sebesar 0,96. Artinya, dari seluruh gambar yang diprediksi sebagai Melon Hijau, 96% memang benar-benar Melon Hijau. Nilai recall-nya bahkan mencapai 1,00, yang menunjukkan bahwa semua gambar Melon Hijau dalam data validasi berhasil dikenali dengan tepat oleh model. Kombinasi dari precision dan recall tersebut menghasilkan nilai f1-score sebesar 0,98, yang menandakan performa yang sangat baik dan konsisten dalam mengklasifikasikan kelas ini.

Sementara itu, pada kelas Melon Orange, nilai precision-nya adalah 1,00, yang berarti setiap prediksi model terhadap Melon Orange selalu tepat dan tidak ada yang salah diklasifikasikan. Namun, nilai recall-nya sedikit lebih rendah, yaitu 0,96, yang mengindikasikan bahwa ada sekitar 4% gambar Melon Orange yang tidak berhasil dikenali sebagai Melon Orange dan mungkin diklasifikasikan sebagai Melon Hijau. Meskipun demikian, nilai f1-score untuk kelas ini juga tetap tinggi, yakni 0,98, yang menunjukkan bahwa performa model untuk kelas Melon Orange hampir setara dengan Melon Hijau.

Secara keseluruhan, model ini memiliki tingkat akurasi sebesar 0,98. Ini berarti bahwa dari 400 gambar pada data validasi, sebanyak 98% berhasil diklasifikasikan dengan benar, hanya 2% gambar yang mengalami kesalahan prediksi. Selain itu, nilai macro average dan

weighted average untuk precision, recall, dan f1-score semuanya juga bernilai 0,98, yang menunjukkan bahwa model bekerja secara seimbang dan adil terhadap kedua kelas, tanpa ada kecenderungan bias ke salah satu kelas saja.

Hasil evaluasi ini membuktikan bahwa arsitektur hybrid CNN-AE bekerja sangat efektif dalam mengenali warna buah melon. CNN membantu dalam mengekstraksi fitur penting dari gambar, seperti tekstur dan bentuk, sedangkan komponen AE membantu model untuk fokus pada area-area gambar yang paling relevan, seperti warna permukaan buah. Kombinasi ini menghasilkan model yang mampu membedakan warna melon dengan tingkat akurasi dan presisi yang tinggi.

#### 4. Kesimpulan

Penelitian ini berhasil membangun dan menguji model hybrid Convolutional Neural Network (CNN)-Attention Enhancement (AE) untuk klasifikasi presisi warna buah melon menjadi dua kelas utama, yaitu hijau dan oranye. Model ini memanfaatkan kekuatan CNN untuk mengekstraksi fitur visual dasar dan modul Attention Enhancement untuk meningkatkan fokus pada area-area penting dalam gambar.

Hasil pelatihan dan evaluasi menunjukkan bahwa model hybrid CNN-AE mampu menghasilkan akurasi yang lebih tinggi dibandingkan dengan model CNN standar. Peningkatan rata-rata akurasi sekitar 5% menjadi bukti bahwa AE memberikan kontribusi positif dengan menyoroti fitur-fitur penting yang relevan, sehingga proses klasifikasi menjadi lebih presisi.

Secara keseluruhan, penelitian ini memberikan kontribusi dalam pengembangan teknologi klasifikasi warna buah melon yang dapat diterapkan dalam industri pertanian. Model yang dihasilkan mampu meningkatkan efisiensi dan akurasi dalam proses seleksi buah melon, mendukung terciptanya sistem pertanian digital yang lebih modern dan handal.

#### Daftar Rujukan

- [1] M. R. Naroui Rad, “Melon selection for breeding based on traits and diversity,” *Current Agriculture Research Journal*, vol. 10, no. 2, pp. 39–45, Sep. 2022, doi: 10.12944/carj.10.2.01.
- [2] M. Pyingkodi *et al.*, “Fruits quality detection using deep learning models: A meta-analysis,” in *Proc. 3rd Int. Conf. Electronics and Sustainable Communication Systems (ICESC)*, 2022, pp. 1–8, doi: 10.1109/ICESC54411.2022.9885289.
- [3] R. R. Calixto *et al.*, “Development of a computer vision approach as a useful tool to assist producers in harvesting yellow melon in northeastern Brazil,” *Computers and Electronics in Agriculture*, vol. 192, p. 106554, 2022, doi: 10.1016/j.compag.2021.106554.
- [4] R. Raut, A. Jadhav, C. Sorte, and A. Chaudhari, “Classification of fruits using convolutional neural networks,” in *Proc. 2nd Int. Conf. Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)*, 2022, pp. 1–4, doi: 10.1109/ICAECT54875.2022.9808070.
- [5] R. Siddiqi, “Comparative performance of various deep learning based models in fruit image classification,” in *Proc. 11th Int. Conf. Advances in Information Technology (IAIT)*, 2020, doi: 10.1145/3406601.3406619.
- [6] M. Bilal M *et al.*, “Automated mango classification using convolutional neural networks (CNN),” *International Journal of Innovative Science and Research Technology (IJISRT)*, pp. 269–275, Sep. 2024, doi: 10.38124/ijisrt/ijisrt24sep163.
- [7] T. Hafiez *et al.*, “Optimasi klasifikasi gambar varietas jenis tomat dengan data augmentation dan convolutional neural network,” *Smart Comp: Jurnalnya Orang Pintar Komputer*, vol. 11, pp. 175–186, Apr. 2022, doi: 10.30591/smartcomp.v1i2.3524.
- [8] F. Masykur, M. B. Setyawan, and K. Winangun, “Epoch optimization on rice leaf image classification using convolutional neural network (CNN) MobileNet,” *CESS (Journal of Computer Engineering, System and Science)*, vol. 7, no. 2, p. 581, Jul. 2022, doi: 10.24114/cess.v7i2.37336.
- [9] D. Ayala-Niño and J. M. González-Camacho, “Evaluation of machine learning models to identify peach varieties based on leaf color,” *Agrociencia*, vol. 56, no. 4, pp. 669–703, Jan. 2022, doi: 10.47163/agrociencia.v56i4.2810.
- [10] J. Chen *et al.*, “Combined effect of ozone treatment and modified atmosphere packaging on antioxidant defense system of fresh-cut green peppers,” *Journal of Food Processing and Preservation*, vol. 40, 2016, doi: 10.1111/jfpp.12695.
- [11] H. Gill and B. Khehra, “Hybrid classifier model for fruit classification,” *Multimedia Tools and Applications*, vol. 80, pp. 1–36, Jul. 2021, doi: 10.1007/s11042-021-10772-9.
- [12] B. Nouné, P. Jones, D. Justus, D. Masters, and C. Luschi, “8-bit numerical formats for deep neural networks,” *arXiv:2206.02915*, Jun. 2022.
- [13] M. A. Shehab *et al.*, “Efficient real-time object detection based on convolutional neural network,” in *Proc. Int. Conf. Applied and Theoretical Electricity (ICATE)*, 2021, pp. 1–5, doi: 10.1109/ICATE49685.2021.9465015.
- [14] J. Jin, “Convolutional neural networks for biometrics applications,” *SHS Web of Conferences*, vol. 144, p. 03013, 2022, doi: 10.1051/shsconf/202214403013.
- [15] D. N. V. S. L. S. Indira *et al.*, “A review on fruit recognition and feature evaluation using CNN,” *Materials Today: Proceedings*, vol. 80, pp. 3438–3443, 2023, doi: 10.1016/j.matpr.2021.07.267.
- [16] A. A. Alfa *et al.*, “Comparative analysis of performances of convolutional neural networks for image classification tasks,” in *Proc. Int. Conf. Recent Innovations in Computing*, 2023, pp. 179–190.
- [17] M. G. S. M. Gajapaka, and L. Baru, “A simple attention block embedded in standard CNN for image classification,” in *Proc. Int. Conf. Advances in Artificial Intelligence and Computing (ICAAIC)*, 2022, doi: 10.1109/ICAAIC53929.2022.9793110.
- [18] S. Zeeshan, T. Aized, and F. Riaz, “The design and evaluation of an orange-fruit detection model in a dynamic environment using a convolutional neural network,” *Sustainability*, vol. 15, p. 4329, 2023, doi: 10.3390/su15054329.
- [19] M. Reyad, A. M. Sarhan, and M. Arafa, “A modified Adam algorithm for deep neural network optimization,” *Neural Computing and Applications*, vol. 35, no. 23, pp. 17095–17112, 2023, doi: 10.1007/s00521-023-08568-z.
- [20] J. Wu *et al.*, “Atrous residual convolutional neural network based on U-Net for retinal vessel segmentation,” *PLoS One*, vol. 17, no. 8, 2022, doi: 10.1371/journal.pone.0273318.
- [21] W. Geng, “Attention-aware CNN for fruit image classification,” *Highlights in Science, Engineering and Technology*, vol. 38, pp. 199–207, 2023, doi: 10.5409/hset.v38i.5806.
- [22] F. Maleki *et al.*, “Generalizability of machine learning models: Quantitative evaluation of three methodological pitfalls.”
- [23] M. Amin, “Confusion matrix in binary classification problems: A step-by-step tutorial,” *Journal of Engineering Research*, vol. 6, 2022, doi: 10.21608/erjeng.2022.274526.