

KLASIFIKASI KUALITAS BUNGA CENGKEH DENGAN METODE FASTER REGION CONVOLUTIONAL NEURAL NETWORK (FASTER R-CNN)

Dayanti^{*1}, Yuyun², Hasriani³, Irwan Syarif⁴, Nur Inda⁵

^{1,4}Universitas Patria Artha, ²Pusat Riset Data dan Informasi Badan Riset dan Inovasi Nasional, ³Universitas Handayani Makassar, ⁵Institut Teknologi dan Bisnis Muhammadiyah Polewali Mandar
e-mail : *¹dayanti.fattah@gmail.com, ²yuyunwabula@handayani.ac.id, ³hazriani@handayani.ac.id, ⁴firaysnawri88@gmail.com, ⁵nurinda@itbpolman.ac.id

Bunga cengkeh memiliki peran penting dalam sektor pertanian, industri, serta aspek kultural. Selain bernilai ekonomis tinggi sebagai rempah, cengkeh juga digunakan dalam industri makanan, farmasi, pengobatan tradisional, dan aromaterapi. Namun, tantangan muncul karena proses penilaian kualitas hasil panen cengkeh masih dilakukan secara subjektif oleh petani dengan indra penglihatan. Penelitian ini bertujuan mengembangkan sistem berbasis kecerdasan buatan untuk membantu petani, produsen, dan konsumen dalam mengklasifikasikan kualitas bunga cengkeh. Metode yang digunakan adalah machine learning dengan algoritma Faster R-CNN. Dataset diperoleh dari lokasi penelitian dan dibagi ke dalam tiga kelas: kualitas baik, sedang, dan buruk. Pengujian dilakukan dengan mempertimbangkan parameter intensitas cahaya (lux), jarak pengambilan objek, serta pembeda terhadap objek lain. Hasil terbaik diperoleh pada kondisi lux 600 dan jarak 17 cm sebagai. Model augmentasi memberikan hasil yang lebih baik dengan akurasi pengujian mencapai 86%, serta mampu mendeteksi objek dengan latar belakang yang lebih kompleks. Model nonaugmentasi menunjukkan performa lebih rendah, dengan akurasi 51%.

Kata Kunci— Bunga Cengkeh, Faster R-CNN, Machine Learning, Mutu.

I. PENDAHULUAN

Bunga cengkeh (*Syzygium aromaticum*) merupakan salah satu komoditas unggulan Indonesia yang memiliki nilai ekonomi tinggi serta peran penting dalam industri makanan, farmasi, hingga pengobatan tradisional. Bagian bunga dari tanaman ini banyak dimanfaatkan karena mengandung senyawa bioaktif seperti flavonoid dan eugenol yang berkhasiat sebagai antioksidan, antibakteri, dan antiinflamasi.[1] Sebagai negara penghasil utama cengkeh, kualitas bunga cengkeh menjadi aspek vital dalam menjaga daya saing produk, namun hingga kini, proses klasifikasi mutu masih dilakukan secara manual oleh petani dengan mengandalkan indra penglihatan, yang cenderung subjektif dan tidak konsisten.[2]

Permasalahan utama dalam budidaya dan pascapanen bunga cengkeh adalah ketidakakuratan dalam penilaian mutu yang dilakukan secara konvensional. Proses klasifikasi yang subjektif berisiko menghasilkan ketidaksesuaian standar mutu, menurunkan harga jual, dan merugikan petani.[3] Penelitian ini menawarkan solusi berupa sistem deteksi kualitas bunga cengkeh menggunakan teknologi kecerdasan buatan, khususnya metode Faster Region Convolutional Neural Network (Faster R-CNN), untuk mengidentifikasi dan mengklasifikasikan kualitas bunga cengkeh secara otomatis dan objektif berdasarkan citra digital.[4]

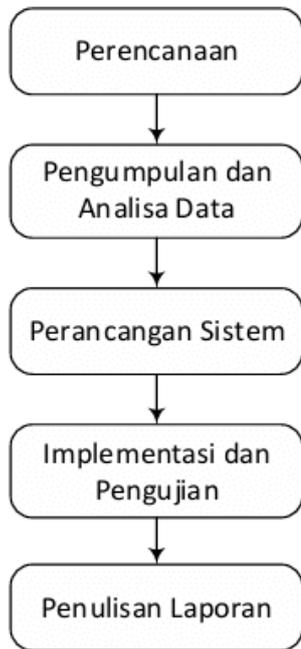
Tujuan kami dalam melakukan penelitian ini adalah menggunakan algoritma Faster R-CNN yang merupakan algoritma deep learning yang efektif dalam tugas deteksi objek, dengan menggunakan Region Proposal Network (RPN) dan Fast R-CNN sebagai detektor yang kuat.[5] Dalam penelitian ini, Faster R-CNN digunakan untuk mengolah dataset gambar bunga cengkeh yang telah diberi anotasi dan augmentasi. Citra dibagi dalam tiga kelas mutu: baik, sedang, dan buruk, berdasarkan warna, ukuran, dan bentuk objek. Proses pelatihan menggunakan data augmentasi seperti rotasi dan resizing bertujuan meningkatkan akurasi model deteksi.

Pengembangan yang dilakukan mencakup preprocessing dataset dengan berbagai kondisi pencahayaan (lux), jarak pengambilan gambar, serta latar belakang objek. Sistem dirancang menggunakan Python dan PyTorch, dengan konfigurasi model yang dioptimalkan melalui pengujian parameter seperti epoch, batch size, dan learning rate.[6] penelitian ini berfokus pada multi-objek dengan data yang lebih kompleks, menunjukkan bahwa penggabungan augmentasi data dan penggunaan Faster R-CNN mampu meningkatkan kinerja sistem klasifikasi mutu bunga cengkeh secara signifikan dan aplikatif di lapangan.

II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen dalam pengembangan sistem

klasifikasi mutu bunga cengkeh berbasis pengolahan citra digital. Penelitian dilakukan secara bertahap melalui perencanaan, pengumpulan data, perancangan sistem, implementasi, dan pengujian sistem menggunakan algoritma Faster Region Convolutional Neural Network (Faster R-CNN). [7]



Gambar 1. Rancangan penelitian

A. Pengumpulan dan Persiapan Data

Data yang digunakan merupakan citra bunga cengkeh dalam kondisi kering, diperoleh langsung dari lokasi pengambilan sampel. Dataset diklasifikasikan ke dalam tiga kelas mutu: kualitas baik, sedang, dan buruk. Masing-masing kelas berisi 200 gambar, menghasilkan total 600 gambar awal. Data kemudian diperbesar melalui teknik augmentasi seperti rotasi, shear, dan resize menjadi total 4.418 data, yang dibagi menjadi:

Tabel 1. Standar Parameter Bunga Cengkeh

Mutu	Warna	Bentuk	Ukuran
Baik	Coklat Kehitam-hitaman	Utuh	2 cm
Sedang	Coklat	Utuh	1,5 cm
Buruk	Coklat	Tidak utuh	1,5 cm

B. Perancangan dan Implementasi Sistem

Sistem dirancang menggunakan framework PyTorch dalam bahasa pemrograman Python. Model Faster R-CNN digunakan dengan struktur Region Proposal Network (RPN) untuk menghasilkan bounding box dari citra input. Parameter utama dalam pelatihan model meliputi: Ukuran gambar input: 416x416 piksel, Epoch: 10, Batch size: 16, Learning rate: 0.001, Momentum: 0.9, Weight decay: 0.0005.

Faster R-CNN model yang cukup besar dan kompleks. Setiap epoch memerlukan waktu pelatihan yang relatif lama, terutama dengan ukuran input 416x416 dan batch size 16. Karena itu, pemilihan 10 epoch bisa kompromi

antara akurasi dan waktu pelatihan. Jumlah dataset yang digunakan relatif kecil, terlalu banyak epoch justru bisa meningkatkan risiko overfitting. Pada kondisi ini, model sudah cukup belajar dalam ≤ 10 epoch.

Tabel 2. Hyperparameter

Hyperparameter	Value
Input Image	416x416
Epoch	10
Batch Size	16
Learning Rate	0.001
Momentum	0.9
Weight_decay	0.0005

C. Faster Region Convolutional Neural Network (Faster R-CNN)

Algoritma Faster Region Convolutional Neural Network (Faster R-CNN) adalah pengembangan dari metode R-CNN dan Fast R-CNN, yang mengintegrasikan proses deteksi wilayah dan klasifikasi objek dalam satu kerangka kerja end-to-end.[8] Pada penelitian ini, Faster R-CNN digunakan untuk melakukan deteksi objek bunga cengkeh dan mengklasifikasikan kualitasnya ke dalam tiga kategori: baik, sedang, dan buruk, berdasarkan parameter visual seperti ukuran, warna, dan bentuk. Proses kerja algoritma Faster R-CNN dalam klasifikasi mutu bunga cengkeh dapat dijelaskan melalui tahapan berikut:

1. Ekstraksi Fitur Citra (Feature Extraction)

Gambar bunga cengkeh dimasukkan ke dalam jaringan *Convolutional Neural Network* (CNN) yang berfungsi sebagai ekstraktor fitur. CNN mengubah citra mentah menjadi representasi numerik berupa *feature map* yang menggambarkan karakteristik visual penting dari bunga cengkeh, seperti tepi, tekstur, dan warna dominan.[9]

2. Region Proposal Network (RPN)

RPN menghasilkan *region proposals* (calon wilayah objek) dari *feature map*. Pada tahap ini, sistem memindai citra menggunakan *sliding window* dan menghasilkan beberapa *anchor boxes* dengan skala dan rasio aspek yang berbeda. Setiap anchor dinilai apakah mengandung objek (bunga cengkeh) atau tidak, menggunakan nilai *Intersection over Union* (IoU).[10]

3. ROI Pooling dan Klasifikasi

Wilayah yang diusulkan oleh RPN kemudian diproses melalui ROI (Region of Interest) Pooling untuk menghasilkan ukuran tetap. Selanjutnya, fitur ini dilewatkan ke dalam lapisan *fully connected* untuk dilakukan klasifikasi ke dalam tiga kelas mutu: baik, sedang, atau buruk. Pada saat yang sama, sistem juga memprediksi koordinat bounding box dari masing-masing objek.[11]

4. Bounding Box Regression dan Non Maximum Suppression

Prediksi bounding box disesuaikan agar tepat membatasi objek bunga cengkeh. Selanjutnya, digunakan *Non-Maximum Suppression* (NMS) untuk menghapus duplikasi deteksi dengan skor kepercayaan rendah, dan hanya menyisakan deteksi terbaik.[12]

5. Output

Sistem akhirnya menghasilkan output berupa gambar dengan bounding box yang telah diklasifikasikan ke dalam salah satu dari tiga kelas mutu. Informasi ini dapat digunakan untuk otomatisasi penilaian mutu cengkeh secara visual dan akurat.

Keunggulan Faster R-CNN dalam penelitian ini adalah kemampuannya mendeteksi multi-objek bunga cengkeh dalam satu gambar dengan ketelitian tinggi dan ketahanan terhadap latar belakang kompleks. Proses pelabelan dan augmentasi data turut membantu dalam meningkatkan generalisasi model terhadap variasi bentuk dan pencahayaan pada bunga cengkeh. Berdasarkan hasil uji sistem, algoritma ini mampu memberikan akurasi klasifikasi hingga 86% dalam kondisi pencahayaan dan jarak optimal (lux 600, 17 cm).

D. Evaluasi dan Pengujian

Evaluasi dilakukan dengan menguji performa sistem pada kondisi pencahayaan yang berbeda (lux 150, 300, 450, 600) dan jarak kamera (17 cm hingga 32 cm). Ditemukan bahwa kombinasi 600 lux dan 17 cm menghasilkan deteksi objek terbaik.

1. Akurasi Deteksi Objek

Akurasi deteksi objek merupakan ukuran performa model dalam mendeteksi keberadaan bungan cengkeh secara tepat pada citra uji. Nilai ini dihitung berdasarkan jumlah objek yang berhasil dideteksi dengan benar dibandingkan dengan jumlah total objek sebenarnya dalam dataset. Sementara itu, setelah objek terdeteksi, akurasi klasifikasi digunakan untuk menilai sejauh mana model mampu mengelompokkan setiap objek ke dalam kelas mutu yang sesuai (baik, sedang, atau buruk). [13]

- Hasil menunjukkan bahwa akurasi deteksi tertinggi sebesar 86% dicapai pada kondisi pencahayaan 600 lux dan jarak kamera 17 cm, yang menunjukkan bahwa kondisi pencahayaan dan jarak pengambilan gambar sangat mempengaruhi kemampuan sistem dalam mendeteksi objek secara tepat.
- Akurasi deteksi ini dinyatakan dalam persentase dan digunakan untuk menilai keandalan sistem dalam mengenali keberadaan bunga cengkeh, terutama dalam kondisi lingkungan berbeda seperti pencahayaan dan sudut pandang

2. Tingkat Kehilangan (Loss)

Loss adalah metrik yang mengukur seberapa jauh prediksi model dari nilai sebenarnya. Dalam konteks ini, digunakan dua jenis loss:

- Training Loss: Mengukur kesalahan prediksi model saat pelatihan. Semakin rendah nilai loss, semakin baik model belajar dari data latih.
- Validation Loss: Mengukur kesalahan prediksi model saat diuji pada data validasi (yang tidak digunakan dalam pelatihan langsung). Ini berfungsi sebagai indikator generalisasi model.

3. Perbandingan Performa Model dengan Augmentasi dan Nonaugmentasi Dataset

Untuk menguji efektivitas augmentasi data, dilakukan dua jenis pelatihan model: satu dengan

dataset asli (nonaugmentasi) dan satu lagi dengan dataset yang diperluas melalui augmentasi (rotasi, shear, resize).[14]

III. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini terdiri dari gambar bunga cengkeh kering yang diambil langsung dari lokasi penelitian. Jumlah dataset asli yang dikumpulkan sebanyak 600 gambar, masing-masing 200 gambar per kelas, dalam format .jpg. Gambar diambil menggunakan kamera Canon 800D dengan bantuan tripod dan pencahayaan buatan. Variabel lingkungan seperti tingkat pencahayaan (lux) dan jarak kamera ke objek (17 cm – 32 cm) turut divariasikan untuk memperkaya karakteristik visual dari citra.

Untuk meningkatkan jumlah dan keragaman data serta mencegah overfitting selama pelatihan model, dilakukan augmentasi data menggunakan platform Roboflow. Teknik augmentasi yang diterapkan mencakup: Resize ke ukuran 416x416 piksel, Rotasi objek antara -15° hingga +15°, Shear horizontal dan vertikal sebesar ±15°.

1. Annotasi Dataset

Proses anotasi dataset dilakukan menggunakan platform Roboflow, yang berfungsi untuk memberi label (labeling) pada setiap objek bunga cengkeh di dalam citra. Pada tahap ini, dilakukan penandaan (bounding box) yang mengelilingi setiap objek bunga cengkeh, disertai dengan penentuan kelas label sesuai kategori mutu, yaitu baik, sedang atau buruk.[15]

2. Augmentasi Resize, Rotasi dan Shear auto-orient digunakan menghapus gambar dari data EXIF, 2) gambar diatur ke ukuran 416pixel.



Gambar 2. Dataset agumentasi

Tahap augmentasi data dilakukan untuk mengatasi overfitting pada model dan juga menambah akurasi inferensi. Dataset dengan background putih 1 objek adalah 200/per kelas, background campur 1 objek adalah 600/kelas, background putih >1 objek adalah 41 sebelum augmentasi total data 1.841 data asli. Setelah augmentasi dataset adalah 1.841*3 Total dataset sebanyak 4.418 data yang dibagi menjadi 88% (3.866 data) train set, 8% (368 data) valid set dan 4% (184 data) test set.

- 3.866 gambar untuk pelatihan (train set),
- 8% (368 gambar) untuk validasi (validation set),
- 4% (184 gambar) untuk pengujian (test set).

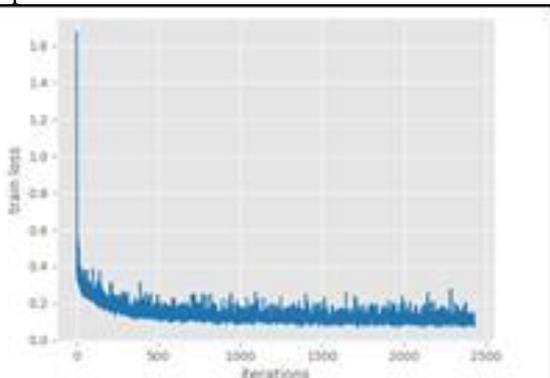
Setiap gambar diberi anotasi (bounding box) yang menandai objek bunga cengkeh serta label mutunya. Proses anotasi dilakukan secara manual menggunakan

bounding box annotation tool di Roboflow untuk menjamin ketepatan pelabelan.

Dataset ini dirancang untuk mendukung klasifikasi multi-objek dalam satu gambar. Beberapa gambar mengandung lebih dari satu bunga cengkeh, baik dalam latar putih bersih maupun latar alami yang kompleks, guna meniru kondisi nyata di lapangan. Pendekatan ini memungkinkan model *Faster R-CNN* belajar mengenali objek dengan latar dan pencahayaan beragam, sehingga meningkatkan kemampuan generalisasi sistem saat diuji di lingkungan baru.

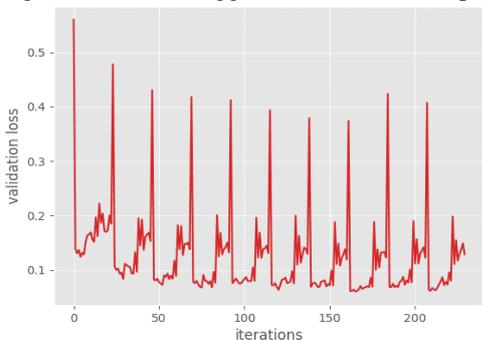
A. Hasil Pelatihan Model

Pelatihan model dilakukan menggunakan dua pendekatan, yaitu dengan dataset augmentasi dan nonaugmentasi, masing-masing dilatih menggunakan arsitektur *Faster R-CNN* yang diimplementasikan dalam framework *PyTorch*. Model dilatih selama 10 epoch dengan ukuran gambar input 416×416 piksel, *batch size* sebesar 16, dan *learning rate* sebesar 0.001. Hasil pelatihan menunjukkan bahwa model dengan dataset augmentasi memberikan *training loss* sebesar **0.106** dan *validation loss* sebesar **0.104**, sementara model nonaugmentasi menghasilkan *training loss* sebesar **0.114** dan *validation loss* sebesar **0.110**. Nilai loss yang lebih rendah pada model augmentasi menunjukkan bahwa model tersebut lebih stabil dalam proses pembelajaran dan memiliki generalisasi yang lebih baik pada data validasi.



Gambar 3. grafik training loss augmentasi

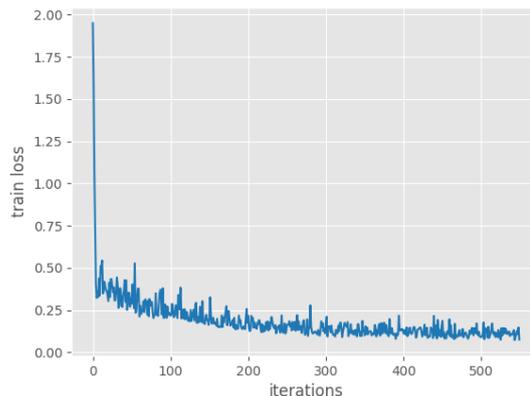
Grafik training loss merupakan performa model, yang melalui proses awal dengan value loss 1.6 hingga proses perjalanan sampai akhir iterations mengalami penurunan loss dengan value loss hingga 0.106 melalui 10 epoch.



Gambar 4. Grafik validasi loss augmentasi

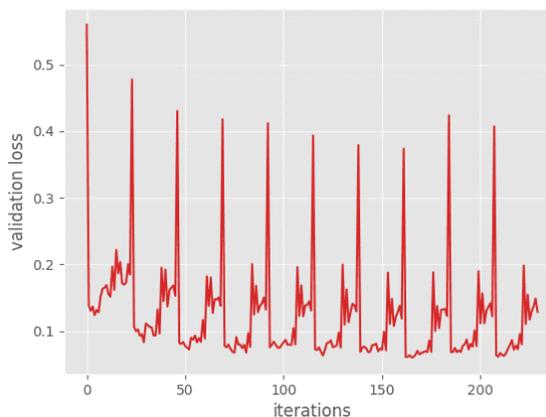
Grafik validasi loss merupakan performa model, yang melalui proses awal dengan value loss di atas 0.5 hingga proses perjalanan sampai akhir iterations mengalami

penurunan loss dengan value loss hingga 0.104 melalui 10 epoch.



Gambar 5. Grafik training loss non-augmentasi

Grafik menunjukkan penurunan nilai training loss terhadap jumlah iterasi selama pelatihan model *Faster R-CNN* dengan augmentasi data. Pada awal iterasi, loss tinggi (sekitar 1.6) lalu menurun tajam hingga stabil di kisaran 0.1–0.2 setelah sekitar 500 iterasi. Penurunan ini menandakan bahwa model berhasil mempelajari pola data dengan baik dan mencapai fase konvergensi.



Gambar 6. Grafik validasi loss non-augmentasi

B. Hasil Pengujian Akurasi Deteksi

Pengujian dilakukan dengan menguji kemampuan model dalam mendeteksi dan mengklasifikasikan objek bunga cengkeh ke dalam tiga kategori mutu: baik, sedang, dan buruk. Uji coba dilakukan dengan variasi parameter pencahayaan (*lux*) dan jarak pengambilan gambar. Hasil terbaik diperoleh pada kombinasi pencahayaan **600 lux** dan jarak **17 cm**, di mana model mampu mendeteksi 18 objek secara akurat dengan tingkat keberhasilan mencapai **86%**.

Pengujian juga dilakukan pada citra uji dengan latar belakang kompleks dan jumlah objek yang bervariasi. Model augmentasi mampu mendeteksi rata-rata lebih banyak objek secara akurat dibandingkan model nonaugmentasi, yang menunjukkan *robustness* yang lebih tinggi terhadap kondisi visual yang beragam.

Tabel 3. pengambilan data berdasarkan cahaya dan jarak

No.	Lux	Jarak (cm)	Gambar
1	150	17 cm	

2	150	22 cm	
3	150	27 cm	
4	150	32 cm	
5	300	17 cm	
6	300	22 cm	
7	300	27 cm	
8	300	32 cm	
9	450	17 cm	
10	450	22 cm	
11	450	27 cm	
12	450	32 cm	
13	600	17 cm	
14	600	22 cm	
15	600	27 cm	
16	600	32 cm	

Data sampel terbaik dengan spesifikasi cahaya lux 600 dan jarak 17 cm antara kamera dengan objek.

Tabel 4. Pengujian deteksi cahaya & jarak

No	Gambar Prediksi	Deteksi Object
1		<ul style="list-style-type: none"> •6 objek baik •6 objek sedang •6 objek buruk

Dengan cahaya 600 dan jarak 17cm dari objek ke kamera. Sistem mendeteksi 6 objek kualitas baik, 6 objek kualitas sedang, 6 objek kualitas buruk.



Gambar 7. Grapik pengujian terdeteksi cahaya dan jarak

Tabel 5. Pengujian Objek deteksi data augmentasi

No	Gambar Prediksi	Deteksi Object
1		<ul style="list-style-type: none"> •6 Objek baik •5 objek buruk •6 objek sedang •1 Objek tidak terdeteksi

Tabel 6. Pengujian Objek deteksi data nonaugmentasi

No	Gambar Prediksi	Deteksi Object
1		<ul style="list-style-type: none"> •4 Objek baik •5 objek buruk •9 Objek tidak terdeteksi
		<ul style="list-style-type: none"> •1 objek lain terdeteksi

C. Perbandingan Performa Augmentasi vs Nonaugmentasi

Perbandingan performa antara model dengan augmentasi dan nonaugmentasi menunjukkan perbedaan signifikan. Model augmentasi berhasil uji sendiri, hasil terbaik diperoleh pada kombinasi pencahayaan 600 lux dan jarak 17 cm, di mana model mampu mendeteksi 18 objek secara akurat dengan meningkatkan akurasi dari 51% mencapai 86% tingkat keberhasilan, terutama pada pengujian dengan citra yang memiliki lebih dari satu objek dan latar belakang bervariasi. Model nonaugmentasi cenderung gagal mendeteksi sebagian objek dan lebih sering memberikan prediksi yang salah, terutama dalam kondisi pencahayaan rendah atau jarak kamera yang tidak optimal.

Data ini mengindikasikan bahwa proses augmentasi data—yang meliputi rotasi, shear, dan resizing—berperan penting dalam memperkaya variasi data latihan, sehingga

membantu model mengenali pola visual bunga cengkeh dalam kondisi yang lebih kompleks.



Gambar 8. Perbandingan Performa Augmentasi vs Nonaugmentasi

D. Interpretasi dan Implikasi

Hasil penelitian ini menunjukkan bahwa metode *Faster R-CNN* efektif dalam mengidentifikasi dan mengklasifikasikan mutu bunga cengkeh berdasarkan ciri visual, dengan tingkat akurasi yang kompetitif. Keberhasilan sistem dalam mendeteksi multi-objek secara bersamaan juga menjadikan pendekatan ini potensial untuk diimplementasikan secara nyata pada sektor pascapanen pertanian, khususnya untuk proses sortasi otomatis.

Dibandingkan dengan metode lain yang digunakan dalam penelitian sebelumnya seperti GLCM, CNN konvensional, atau HSV, model *Faster R-CNN* dalam penelitian ini menunjukkan performa yang lebih adaptif terhadap berbagai kondisi data dan mampu mempertahankan akurasi tinggi dalam skenario nyata. Ini memberikan kontribusi penting terhadap upaya digitalisasi pertanian melalui penerapan teknologi kecerdasan buatan.

IV. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil dan pembahasan dari pembuatan sistem untuk mendeteksi kualitas pada bunga cengkeh dengan metode *faster R-CNN* yang telah dilakukan, maka dapat disimpulkan :1.Metode *Faster Region Convolutional Neural Network* dapat mendeteksi jenis bunga cengkeh. 2.Hasil terbaik diperoleh pada kondisi lux 600 dan jarak 17 cm sebagai. 3.Model augmentasi memberikan hasil yang lebih baik dengan akurasi pengujian mencapai 86%, serta mampu mendeteksi objek dengan latar belakang yang lebih kompleks. 4.Model nonaugmentasi menunjukkan performa lebih rendah, dengan akurasi 51%, dan lebih banyak objek yang tidak terdeteksi atau salah klasifikasi.

B. Saran

Menyesuaikan parameter pada model yang akan digunakan untuk kasus khusus. dengan penyetulan tertentu yang perlu dilakukan untuk meningkatkan keakuratan atau keandalan deteksi. 2. Validasi dengan Data Uji yang Beragam, Pastikan bahwa data uji yang digunakan mewakili variasi kondisi nyata yang mungkin dihadapi oleh sistem deteksi. Analisis ini dapat membantu menilai sejauh mana model dapat berkinerja dengan baik di berbagai lingkungan dan situasi.

DAFTAR PUSTAKA

- [1] M. Syzygium aromaticum L, "Cengkeh (Syzygium Aromaticum L.) Menggunakan," vol. 6.
- [2] R. Munawaroh, "Analisis Mutu Minyak Atsiri Bunga Cengkeh (Syzygium Aromaticum (L.) Meer. & Perry) Dari Maluku, Sumatera, Sulawesi Dan Jawa Dengan Metode Metabolomic Berbasis Gc-MS," *Pharmakon*, vol. 11, no. 2, pp. 57–61, Jan. 2015, doi: 10.23917/pharmakon.v11i2.56.
- [3] I. Y. Prayogi, "Klasifikasi Mutu Cengkeh, DCNN, Hyperparameter CNN, Classification of Clove, Deep Convolutional Neural Network (DCNN), Hyperparameter CNN," 2021, [Online]. Available: <http://repository.ub.ac.id/eprint/187789>
- [4] Fino Charli, Hadi Syaputra, Muhammad Akbar, Siti Suda, Febriyanti Panjaitan, "Implementasi Metode *Faster Region Convolutional Neural Network (Faster R-CNN)* Untuk Pengenalan Jenis Burung Lovebird," *Journal of Information Technology Ampera*, vol. 1, no. 3, Dec. 2020, doi: 10.51519/journalita.volume1.issue3.year2020.page185-197.
- [5] V. K. Sharma and R. N. Mir, "Saliency guided faster-RCNN (SGFr-RCNN) model for object detection and recognition," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 5, pp. 1687–1699, May 2022, doi: 10.1016/j.jksuci.2019.09.012.
- [6] Y. N. Yaspin, D. W. Widodo, and J. Sulaksono, "Klasifikasi Kualitas Bunga Cengkeh untuk Meningkatkan Mutu Dengan Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM)," *Seminar Nasional Inovasi Teknologi*, 2020.
- [7] M. M. Mijwil, K. Aggarwal, R. Doshi, K. K. Hiran, and M. Gök, "The Distinction between R-CNN and Fast R-CNN in Image Analysis: A Performance Comparison," *AJAS*, vol. 10, no. 5, Nov. 2022, doi: 10.24203/ajas.v10i5.7064.
- [8] Dhimas Tribuana, Hazriani, Abdul Latief Arda, "Image Preprocessing Approaches Toward Better Learning Performance with CNN," *JURNAL RESTI(Rekayas a Sistem dan T eknol ogi Informasi)*, vol. 8, no. 1, Jan. 2024, doi: <https://doi.org/10.29207/resti.v8i1.5417>.
- [9] Arya Prayoga, Mainumah, Pristi Sukmasetya, "Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta," *Jou Rnal Of Applied Com Puter Science And Technology (Jacost)*, vol. 4, no. 2, Dec. 2023, doi: <https://doi.org/10.52158/jacost.v4i2.486>.
- [10] Gede ardi pratama, eva yulia puspaningrum, hendra maulana, "Convolutional Neural Network Dan *Faster Region Convolutional Neural Network* Untuk Klasifikasi Kualitas Biji Kopi Arabika," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 12, no. 3, Aug. 2024, doi: <https://doi.org/10.23960/jitet.v12i3.4887>.
- [11] jasman pardede, hendri hardiansah, "Deteksi Objek Kereta Api menggunakan Metode *Faster R-CNN* dengan Arsitektur VGG 16," *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, vol. 7, no. 1, Jun. 2022, doi: <https://doi.org/10.26760/mindjournal.v7i1.21-36>.
- [12] Andrew J. Shepley, Greg Falzon, Paul Kwan, Ljiljana Brankovic, "Confluence: A Robust Non-IoU Alternative to Non-Maxima Suppression in Object Detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 10, oktober 2023, doi: 10.1109/TPAMI.2023.3273210.
- [13] D. Iskandar Mulyana and M. A. Rofik, "Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5," *jptam*, vol. 6, no. 3, pp. 13971–13982, Jul. 2022, doi: 10.31004/jptam.v6i3.4825.
- [14] E. Tarisa and F. Ariany, "Perbandingan Kinerja Deep Learning Lenet Dan Alexnet Dengan Augmentasi Data Pada Identifikasi Anggrek," *JIKA*, vol. 8, no. 1, p. 51, Jan. 2024, doi: 10.31000/jika.v8i1.9923.
- [15] S. Saepudin, N. Sujana, M. M. Mutofar, and A. A. Haryanto, "Analisis Kinerja Yolov8 Optimalisasi Roboflow Untuk Deteksi Ekspresi Wajah Emosional Dengan Machine Learning," *Naratif*, vol. 6, no. 2, pp. 115–124, Dec. 2024, doi: 10.53580/naratif.v6i2.292.