

Klasifikasi Cengkeh Menggunakan Metode Convolutional Neural Network (CNN)

Lisna Ariani^a, Dolly Indra^b, Fitriyani Umar^c

Universitas Muslim Indonesia, Makassar, Indonesia

Email: ^a13020210230@umi.ac.id; ^bdolly.indra@umi.ac.id; ^cfitriyani.umar@umi.ac.id

Received: 07-08-2025 | Revised: 20-08-2025 | Accepted: 13-09-2025 | Published: 29-09-2025

Abstrak

Cengkeh merupakan salah satu komoditas unggulan di sektor pertanian Indonesia yang memiliki nilai ekonomi tinggi, namun rentan mengalami penurunan kualitas akibat kontaminasi jamur selama proses panen dan pascapanen. Selama ini, proses klasifikasi cengkeh berjamur dan tidak berjamur masih dilakukan secara manual, yang cenderung tidak efisien, subjektif, dan berpotensi menimbulkan inkonsistensi, terutama ketika harus menangani volume data dalam jumlah besar. Oleh karena itu, penelitian ini dirancang untuk mengembangkan sistem klasifikasi otomatis berbasis kecerdasan buatan menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur InceptionV3. Penelitian akan dilakukan di Kecamatan Lasusua, Kabupaten Kolaka Utara, dengan menggunakan dataset sebanyak 1.000 citra digital cengkeh yang diambil dari dua pose berbeda. Seluruh citra akan melalui tahapan preprocessing dan augmentasi guna memperkuat kualitas dan keragaman data, sebelum digunakan dalam proses pelatihan model CNN. Evaluasi terhadap performa model akan dilakukan dengan mengukur nilai akurasi, presisi, recall, dan F1-score untuk menentukan sejauh mana efektivitas sistem dalam mengklasifikasikan cengkeh ke dalam dua kelas, yaitu berjamur dan tidak berjamur. Diharapkan hasil dari penelitian ini dapat memberikan kontribusi nyata terhadap peningkatan efisiensi, akurasi, dan objektivitas dalam proses sortasi cengkeh serta menjadi langkah awal dalam penerapan teknologi deep learning untuk mendukung digitalisasi mutu hasil pertanian, khususnya pada komoditas strategis seperti cengkeh.

Kata kunci: Klasifikasi Cengkeh, CNN, Inceptionv3, Citra Digital, Deep Learning

Pendahuluan

Cengkeh (*Syzygium aromaticum*) merupakan salah satu komoditas strategis di sektor pertanian Indonesia. Tanaman ini banyak dimanfaatkan dalam berbagai industri seperti rokok, farmasi, dan kosmetik [1]. Sebagai salah satu negara eksportir cengkeh terbesar di dunia, kualitas hasil panen menjadi aspek penting dalam menentukan daya saing dan nilai jual produk. Namun demikian, kualitas cengkeh kerap mengalami penurunan akibat kontaminasi jamur. Tidak hanya menurunkan mutu dan harga jual, kontaminasi ini juga berisiko terhadap kesehatan karena potensi kandungan mikotoksin [2].

Salah satu permasalahan serius yang sering dihadapi oleh petani maupun pelaku industri adalah pertumbuhan jamur pada cengkeh yang disebabkan oleh kelembaban tinggi atau penanganan yang kurang higienis. Cengkeh yang terinfeksi jamur umumnya menunjukkan ciri visual yang cukup jelas, seperti munculnya bercak putih, keabu-abuan, hingga kehijauan pada permukaannya. Dalam beberapa kasus, jamur membentuk lapisan halus seperti kapas yang dapat dilihat pada bagian batang maupun kepala bunga cengkeh. Kondisi ini selain menurunkan nilai jual cengkeh, juga dapat menyebabkan risiko kesehatan karena kemungkinan terbentuknya mikotoksin berbahaya [3].



Gambar 1 Cengkeh Berjamur

Sebaliknya, cengkeh yang tidak berjamur memiliki tampilan fisik yang bersih, kering, dan berwarna cokelat tua kehitaman secara merata. Permukaannya kering dan tidak menunjukkan adanya tanda-tanda kontaminasi. Cengkeh yang sehat juga memiliki aroma khas yang kuat dan menyengat, yang menjadi salah satu indikator kualitasnya. Citra cengkeh normal menunjukkan bentuk cengkeh utuh yang bebas jamur dengan kondisi visual yang baik. Tidak terdapat bercak atau pertumbuhan mikroorganisme di bagian permukaannya, dan struktur cengkeh tampak kokoh [3].



Gambar 2 Cengkeh Tidak Berjamur

Proses sortasi cengkeh yang selama ini dilakukan secara manual sangat bergantung pada pengamatan visual manusia yang bersifat subjektif, kurang efisien, dan rawan kesalahan, terutama saat menghadapi volume besar dan kondisi visual yang bervariasi. Hal ini mendorong perlunya sistem klasifikasi otomatis yang akurat dan konsisten [4].

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence) membuka peluang penerapan metode *Deep Learning* dalam sektor pertanian, khususnya klasifikasi citra. Salah satu metode yang populer adalah *Convolutional Neural Network* (CNN) [5], yang mampu mengekstraksi fitur visual dari gambar secara otomatis dan akurat tanpa memerlukan pemrograman fitur manual yang rumit. CNN terbukti efektif dalam berbagai tugas pengenalan pola visual di bidang medis, manufaktur, dan pertanian [6].

Penelitian ini memanfaatkan arsitektur *InceptionV3*, sebuah varian CNN yang dikenal memiliki keunggulan dalam akurasi tinggi dan efisiensi komputasi. *InceptionV3* dirancang untuk mengolah berbagai ukuran fitur visual dalam satu lapisan, memungkinkan model mengenali pola-pola kompleks secara lebih baik. Keunggulan ini sangat relevan untuk mendeteksi karakteristik visual pada cengkeh yang berjamur, seperti perubahan warna, tekstur, dan noda permukaan [7].

Penelitian ini dilakukan beberapa tahapan yang terstruktur, dimulai dari tahap perencanaan data yang mencakup observasi langsung di lokasi pengolahan cengkeh, pengumpulan data citra, pelabelan data ke dalam dua kelas (berjamur dan tidak berjamur), serta pembagian dataset untuk pelatihan dan pengujian. Selanjutnya, pada tahap desain model, dilakukan preprocessing citra berupa resize, normalisasi, dan augmentasi, perancangan arsitektur CNN menggunakan *InceptionV3*, serta konfigurasi parameter pelatihan. Tahap berikutnya adalah pelatihan dan evaluasi model, di mana 80% data digunakan untuk pelatihan dan 20% sisanya untuk pengujian awal, dengan pengukuran performa melalui metrik klasifikasi seperti akurasi. Terakhir, tahap *cutover* atau implementasi dilakukan dengan menguji model pada citra baru dari skenario nyata untuk mengevaluasi kinerja sistem dalam kondisi non-laboratorium.

Sejumlah penelitian terdahulu telah mengembangkan sistem klasifikasi cengkeh berbasis CNN. Penelitian berjudul "*Classification of Clove Types Using Convolution Neural Network Algorithm with Optimizing Hyperparameters*" menggunakan metode CNN dasar serta arsitektur transfer learning seperti VGG16 dan DenseNet151. Dalam proses klasifikasinya, model dilatih untuk membedakan jenis cengkeh sesuai standar ISO ke dalam kategori *whole*, *headless*, dan *mother clove*. Hasil eksperimen menunjukkan bahwa model VGG16 dengan optimasi parameter mampu mencapai akurasi hingga 99,11%, jauh lebih tinggi dibanding model CNN tanpa transfer learning [8].

Penelitian yang berjudul "Klasifikasi Kualitas Cengkeh Menggunakan Arsitektur ResNet50V2" mengimplementasikan arsitektur CNN ResNet50V2 untuk mendeteksi kualitas visual cengkeh. Dataset terdiri dari 1.250 gambar dengan preprocessing seperti pemotongan dan resize ke 224x224 piksel. Hasil pelatihan

menunjukkan bahwa ResNet50V2 menghasilkan akurasi sebesar 98,80%, dengan stabilitas model yang tinggi tanpa gejala overfitting, membuktikan efektivitas CNN modern untuk klasifikasi mutu berbasis citra [2].

Penelitian “*Classification of Dried Clove Flower Quality Using Convolutional Neural Network*” mengembangkan sistem klasifikasi mutu cengkeh kering menggunakan CNN. Gambar cengkeh dibagi ke dalam empat kelas mutu, dan fitur warna menjadi komponen utama dalam pengenalan. Dengan pendekatan standar CNN dan tanpa banyak eksperimen pada parameter pelatihan, penelitian ini berhasil mencatat akurasi 87,75%, menegaskan potensi CNN dalam pengolahan citra hasil pertanian [9].

Studi berjudul “*Improving System Accuracy by Modifying the Transfer Learning Architecture for Detecting Clove Maturity Levels*” memanfaatkan arsitektur VGG16, VGG19, dan ResNet50 yang dimodifikasi untuk mendeteksi tingkat kematangan cengkeh sebagai indikator mutu. Dataset terdiri dari 955 gambar yang diproses melalui tahapan training dan testing dengan modifikasi tiga layer tambahan. Hasilnya, model VGG16 yang dimodifikasi mencapai akurasi tertinggi yaitu 95,5%, membuktikan bahwa penyesuaian arsitektur CNN dapat meningkatkan performa dalam tugas klasifikasi berbasis visual [10].

Penelitian ini berbeda dari penelitian sebelumnya dalam beberapa hal. Pertama, fokus klasifikasinya bukan pada jenis atau tingkat kematangan, melainkan pada deteksi keberadaan jamur sebagai parameter mutu penting. Kedua, pendekatan pengambilan gambar dilakukan dengan dua sudut pandang (pose), yang bertujuan untuk meningkatkan generalisasi model. Ketiga, arsitektur yang digunakan adalah *InceptionV3*, yang masih jarang diaplikasikan secara spesifik dalam konteks klasifikasi cengkeh berjamur.

Penelitian ini bertujuan untuk merancang dan menerapkan sistem klasifikasi otomatis untuk membedakan cengkeh berjamur dan tidak berjamur menggunakan metode CNN berbasis *InceptionV3*. Diharapkan sistem ini dapat meningkatkan efisiensi dan objektivitas proses sortasi, serta menjadi langkah konkret dalam penerapan teknologi digital di sektor pertanian. Dengan pendekatan yang terstruktur dan pemanfaatan teknologi *deep learning* modern, penelitian ini diharapkan dapat menjadi kontribusi nyata dalam pemecahan masalah sortasi mutu cengkeh secara otomatis, cepat, dan akurat.

Metode

Penelitian ini termasuk dalam jenis penelitian rekayasa (*engineering research*) dengan pendekatan kuantitatif eksperimental. Tujuannya adalah merancang sistem klasifikasi otomatis untuk membedakan cengkeh berjamur dan tidak berjamur menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *InceptionV3*.

A. Waktu dan Lokasi

Penelitian ini dilakukan di Kecamatan Lasusua, Kabupaten Kolaka Utara, pada bulan Juli 2025. Lokasi ini dipilih karena merupakan wilayah penghasil cengkeh yang signifikan dan memiliki potensi permasalahan jamur pada hasil panen.

B. Pengujian Sistem CNN dengan Arsitektur InceptionV3

Pengujian sistem CNN dengan arsitektur *InceptionV3* dilakukan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra cengkeh ke dalam dua kelas, yaitu berjamur dan tidak berjamur. Pengujian dilakukan menggunakan 20% data uji yang sebelumnya tidak digunakan dalam proses pelatihan, sehingga mampu memberikan gambaran performa model terhadap data baru. Model yang telah dilatih akan memproses citra-citra uji dan menghasilkan prediksi kelas, yang kemudian dibandingkan dengan label asli untuk menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score. Selain itu, pengujian ini juga mencakup analisis confusion matrix untuk melihat distribusi prediksi benar dan salah. Evaluasi ini penting untuk memastikan bahwa model bekerja secara optimal dalam kondisi nyata dan dapat diandalkan dalam proses klasifikasi cengkeh secara otomatis.


C. Cara Pengumpulan Data

Data citra cengkeh diperoleh melalui pemotretan langsung di lokasi penelitian (Kecamatan Lasusua, Kab. Kolaka Utara) dengan pencahayaan alami dan berbagai sudut pengambilan untuk mendapatkan variasi 2 pose. Setiap gambar kemudian diklasifikasikan menjadi dua kelas, berjamur dan tidak berjamur, sesuai kondisi nyata. Data selanjutnya disimpan dalam format digital untuk pemrosesan selanjutnya.

Perancangan

A. Instrumen Penelitian

1. Perangkat Keras (*Hardware*)
 - a) Citra digital berjamur dan tidak berjamur sebanyak 1.000 gambar (500 per kelas).
 - b) Kamera digital dengan resolusi minimal 12 MP untuk pengambilan gambar cengkeh.
 - c) Komputer dengan spesifikasi memadai (GPU minimal NVIDIA GTX 1060 atau setara) untuk pelatihan model CNN.
2. Perangkat Lunak (*Software*)
 - a) Perangkat lunak Python dengan *library deep learning* seperti TensorFlow/Keras.
 - b) Software pendukung lain seperti OpenCV untuk *preprocessing* gambar



Gambar 3 Bagan Tahapan Penelitian

B. Perencanaan Data (*Data Planning*)

Adapun tahapan Data Planning, yaitu:

1. Observasi dan Identifikasi Permasalahan


Penelitian ini diawali dengan observasi langsung terhadap proses klasifikasi cengkeh berjamur dan tidak berjamur secara manual yang dilakukan di **Kecamatan Lasusua, Kabupaten Kolaka Utara**. Proses klasifikasi secara konvensional dinilai tidak efisien, subjektif, dan rawan kesalahan, terutama ketika volume data besar dan kondisi visual cengkeh bervariasi.
2. Studi Literatur

Literatur ditelaah untuk mendalami metode klasifikasi citra menggunakan *Convolutional Neural Network* (CNN), khususnya arsitektur InceptionV3. Referensi yang digunakan mencakup studi klasifikasi visual hasil pertanian serta pengolahan citra digital dalam bidang pertanian dan industri makanan.

3. **Perencanaan Dataset**
Dataset dirancang menggunakan 1.000 citra cengkeh, terdiri dari 500 citra cengkeh berjamur dan 500 citra cengkeh tidak berjamur. Setiap cengkeh difoto dari 2 pose untuk menangkap variasi visual. Dataset ini kemudian akan di-*split* dengan rasio **80:20** untuk data pelatihan dan pengujian.
- C. **Desain Model CNN (*Model Design*)**
1. ***Preprocessing Data***
Citra mengalami preprocessing yang mencakup *resizing*, normalisasi piksel, dan augmentasi data seperti rotasi atau *flipping*. Data diberi label dua kelas, yaitu “*Berjamur*” dan “*Tidak berjamur*”, untuk memudahkan pelatihan model klasifikasi biner.
 2. **Desain Arsitektur InceptionV3**
Digunakan arsitektur InceptionV3 karena efisien dalam mengenali pola kompleks dalam citra. Lapisan-lapisan Inception digunakan untuk menangkap informasi visual multi-skala, sedangkan bagian akhir disesuaikan untuk dua kelas output.
 3. ***Training dan Validasi Prototipe Model***
Model dilatih menggunakan 80% data, sementara 20% sisanya digunakan untuk validasi awal. Parameter pelatihan seperti *epoch*, *batch size*, dan *learning rate* ditentukan berdasarkan eksperimen awal untuk menghasilkan model yang optimal.
 4. **Konstruksi dan Evaluasi (*Construction and Evaluation*)**
Setelah model akhir disepakati, dilakukan pelatihan ulang menggunakan seluruh data pelatihan, dan kemudian diuji dengan data uji (*testing dataset*) yang sebelumnya belum pernah digunakan. Evaluasi model dilakukan menggunakan metrik seperti akurasi, precision, recall, dan confusion matrix untuk mengukur performa klasifikasi.
 5. ***Cutover (Implementasi dan Uji Model)***
Model akhir kemudian diterapkan untuk mengklasifikasikan citra baru dalam skenario uji lapangan. Sistem ini diuji menggunakan rasio 80:20, di mana 80% digunakan untuk pelatihan dan 20% untuk pengujian performa terhadap data yang belum dikenali. Hasil uji ini digunakan untuk menilai keakuratan sistem dalam kondisi nyata.

Pemodelan

- A. **Perencanaan Dataset**
Dataset dirancang menggunakan 1.000 citra cengkeh, terdiri dari 500 citra cengkeh berjamur dan 500 citra cengkeh tidak berjamur. Setiap cengkeh difoto dari 2 pose untuk menangkap variasi visual. Dataset ini kemudian akan di-*split* dengan rasio 80:20 untuk data pelatihan dan pengujian.
- B. ***Preprocessing Data***
Citra mengalami preprocessing yang mencakup *resizing*, normalisasi piksel, dan augmentasi data seperti rotasi atau *flipping*. Data diberi label dua kelas, yaitu “*Berjamur*” dan “*Tidak berjamur*”, untuk memudahkan pelatihan model klasifikasi biner.
- C. **Desain Arsitektur InceptionV3**
Digunakan arsitektur InceptionV3 karena efisien dalam mengenali pola kompleks dalam citra. Lapisan-lapisan Inception digunakan untuk menangkap informasi visual multi-skala, sedangkan bagian akhir disesuaikan untuk dua kelas output [11].
- Arsitektur InceptionV3 yang digunakan dalam penelitian ini dirancang untuk melakukan klasifikasi citra cengkeh ke dalam dua kelas, yaitu *berjamur* dan *tidak berjamur*. InceptionV3 merupakan pengembangan dari arsitektur Inception sebelumnya (V1 dan V2) yang dikenal unggul dalam efisiensi komputasi dan akurasi klasifikasi citra berskala besar seperti ImageNet. Dalam penelitian ini, arsitektur InceptionV3 dimodifikasi agar dapat mengakomodasi dua kelas output sesuai kebutuhan klasifikasi cengkeh.



[12]

Gambar 3 Arsitektur InceptionV3

Secara umum, desain arsitektur model mengikuti struktur berikut:

1. Input Layer: Citra cengkeh yang telah melalui preprocessing (resize ke 299x299 piksel, augmentasi, dan normalisasi) dimasukkan sebagai input berukuran 299x299x3.
2. Inception Module A ($\times 5$): Lima blok awal menggunakan *Inception Module A* yang terdiri dari beberapa kombinasi operasi konvolusi dengan ukuran kernel berbeda (1x1, 3x3, dan 5x5) dan pooling, yang disusun secara paralel dan digabungkan (concatenation). Tujuannya adalah mengekstraksi fitur dari berbagai skala visual.
3. Grid Size Reduction 1: Dilakukan pengurangan resolusi (spatial size) dengan teknik pooling dan konvolusi dengan stride, bertujuan mengurangi dimensi fitur sekaligus menjaga informasi penting.
4. Inception Module B ($\times 4$): Empat modul selanjutnya memanfaatkan *Inception Module B* yang mengadopsi konsep *factorized convolutions* untuk meningkatkan efisiensi komputasi, menggantikan konvolusi besar seperti 5x5 menjadi dua buah 3x3 secara berurutan.
5. Grid Size Reduction 2: Tahap kedua pengurangan dimensi dilakukan untuk lebih mengompresi ukuran fitur menjadi lebih kecil, memudahkan proses klasifikasi di akhir.
6. Inception Module C ($\times 2$): Dua modul akhir adalah *Inception Module C* yang lebih dalam dan kompleks, fokus pada ekstraksi fitur tinggi dengan kombinasi konvolusi 1x1 dan 7x1/1x7 untuk menangkap korelasi spasial jangka panjang dalam citra.
7. Auxiliary Classifier: Sebuah *auxiliary classifier* (klasifikasi tambahan) diletakkan di tengah jaringan untuk membantu proses pelatihan dan menghindari vanishing gradient, terutama pada jaringan yang sangat dalam.
8. Final Layers:
 - a. *Average Pooling Layer*: Menggabungkan seluruh fitur dari modul akhir.
 - b. *Dropout Layer*: Digunakan untuk mencegah overfitting.
 - c. *Fully Connected Layer*: Menghubungkan seluruh neuron hasil ekstraksi fitur ke dua output.
 - d. *Softmax Output Layer*: Memberikan output probabilitas klasifikasi ke dalam dua kelas: berjamur dan tidak berjamur.

Output akhir dari model ini berbentuk tensor berukuran 8x8x2048, yang kemudian diringkas menjadi vektor 1x2 melalui lapisan *fully connected* dan *softmax*.

D. Training dan Validasi Prototipe Model

Model dilatih menggunakan 80% data, sementara 20% sisanya digunakan untuk validasi awal. Parameter pelatihan seperti *epoch*, *batch size*, dan *learning rate* ditentukan berdasarkan eksperimen awal untuk menghasilkan model yang optimal.

E. Evaluasi Model

Evaluasi model bertujuan untuk mengukur seberapa baik model CNN dalam hal ini InceptionV3 mampu mengenali dan mengklasifikasikan citra sesuai label yang benar [13]. Beberapa metrik evaluasi utama yang digunakan antara lain akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*. Metrik-metrik ini dihitung berdasarkan hasil klasifikasi terhadap data uji (*testing set*), dengan menggunakan konsep dasar *confusion matrix* yang terdiri dari [14]:

- 1) TP (*True Positive*): Prediksi benar untuk kelas positif (misalnya: cengkeh berjamur yang terklasifikasi berjamur).
- 2) TN (*True Negative*): Prediksi benar untuk kelas negatif (cengkeh tidak berjamur yang diklasifikasi benar).
- 3) FP (*False Positive*): Salah prediksi untuk kelas negatif (cengkeh tidak berjamur tapi diprediksi berjamur).
- 4) FN (*False Negative*): Salah prediksi untuk kelas positif (cengkeh berjamur tapi diprediksi tidak berjamur).

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

[15]

Gambar 4. *Confusion Matrix*

Evaluasi adalah tahap pengukuran kinerja model setelah pelatihan, yang bertujuan untuk mengetahui seberapa baik model dalam menghasilkan prediksi yang sesuai terhadap data yang belum pernah dilihat sebelumnya. Proses evaluasi dilakukan setelah model menyelesaikan proses pelatihan. Pada tahap ini, metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* digunakan untuk mengukur kinerja dari masing-masing model terhadap data pengujian. Hasil kemudian menjadi dasar untuk membandingkan efektivitas dari kedua model dalam mendeteksi produk boikot berdasarkan input gambar.

Akurasi mengukur seberapa tepat model dalam mengklasifikasikan data secara keseluruhan, baik positif maupun negatif. Presisi menilai ketepatan model dalam memprediksi kelas positif, sedangkan *recall* menunjukkan seberapa baik model dalam menemukan semua data positif yang sebenarnya [16][17]. *F1-score* digunakan untuk menyeimbangkan presisi dan *recall*, terutama saat distribusi data tidak seimbang. Keempat metrik ini penting untuk mengevaluasi performa model dalam tugas klasifikasi. Berikut persamaan metrik ditunjukkan pada persamaan (1)-(4). [14]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Presisi = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (4)$$

Kesimpulan

Penelitian ini direncanakan untuk merancang, menerapkan, dan mengevaluasi sistem klasifikasi citra cengkeh menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur InceptionV3. Sistem ini diharapkan mampu mengklasifikasikan cengkeh berjamur dan tidak berjamur secara otomatis dengan tingkat akurasi yang tinggi. CNN akan digunakan untuk mengekstraksi fitur visual secara langsung dari citra cengkeh dan mengelompokkannya ke dalam dua kelas utama tanpa memerlukan proses manual yang kompleks. Penerapan metode *deep learning* ini ditargetkan dapat meningkatkan efisiensi dan objektivitas proses sortasi cengkeh, yang selama ini masih bergantung pada penilaian manusia yang bersifat subjektif dan tidak konsisten. Dengan demikian, penelitian ini bertujuan untuk membuktikan bahwa sistem klasifikasi otomatis berbasis CNN dapat menjadi solusi baru yang lebih cepat, akurat, dan andal dalam mendeteksi kualitas hasil pertanian, khususnya pada komoditas cengkeh. Selain itu, penelitian ini juga akan mengkaji sejauh mana model CNN-InceptionV3 mampu memenuhi kebutuhan klasifikasi visual dalam konteks klasifikasi biner (berjamur dan tidak berjamur), dengan mengevaluasi performa model berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score*. Hipotesis dalam penelitian ini adalah bahwa metode CNN dapat digunakan secara efektif sebagai sistem klasifikasi mutu cengkeh. Jika terbukti efektif, sistem ini akan menjadi landasan bagi pengembangan teknologi klasifikasi berbasis kecerdasan buatan yang dapat diterapkan secara luas di sektor pertanian, khususnya dalam mendukung transformasi digital di bidang pengolahan hasil panen.

Daftar Pustaka

- [1] U. W. Sari, D. Sari, and U. Rofiatin, "ANALISIS PROSPEK CENGKIH DI INDONESIA (Analysis of Clove Prospects in Indonesia)," *SSRN Electron. J.*, no. November, 2023, doi: 10.2139/ssrn.4326423.
- [2] M. N. Linggama and D. Ariatmanto, "Klasifikasi Kualitas Cengkeh menggunakan Arsitektur Clove Quality Classification using the ResNet50V2 Architecture," vol. 14, pp. 872–882, 2025.
- [3] H. Syahfari and A. S. Ramayana, *Buku Ajar Dasar-Dasar Perlindungan Tanaman Cengkeh*. Penerbit NEM, 2024.
- [4] Solopos.com, "Terserang Jamur, Ribuan Pohon Cengkih di Karangtengah Mati," Jawa Tengah, 2020. [Online]. Available: <https://www.liputan6.com/regional/read/4189661/terserang-jamur-ribuan-pohon-cengkih-di-karangtengah-mati>
- [5] R. A. Putri *et al.*, "Model Deep Learning Untuk Klasifikasi Objek Pada Gambar Fisheye," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 3, pp. 519–528, 2024, doi: 10.25126/jtiik.938047.
- [6] R. Ardianto and S. K. Wibisono, "Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum," *J. Kolaboratif Sains*, vol. 6, no. 12, pp. 2081–2092, 2023.
- [7] E. Andreas and W. Widhiarso, "Convolutional Neural Network Dengan Arsitektur Inception V3," *MDP Student Conf.*, vol. 2, no. 1, pp. 107–113, 2023, doi: 10.35957/mdp-sc.v2i1.3660.
- [8] F. Tempola, R. Wardoyo, A. Musdholifah, R. Rosihan, and L. Sumaryanti, "Classification of clove types using convolution neural network algorithm with optimizing hyperparameters," *Bull. Electr. Eng. Informatics*, vol. 13, no. 1, pp. 444–452, 2024.
- [9] F. A. Chalikh and W. F. Al Maki, "Classification of dried clove flower quality using convolutional neural network," in *2021 International Conference on Data Science, Artificial Intelligence, and Business Analytics (DATABIA)*, IEEE, 2021, pp. 40–45.
- [10] F. T. Rosihan, M. N. Sutoyo, and C. E. Gunawan, "Improving System Accuracy by Modifying the Transfer Learning Architecture for Detecting Clove Maturity Levels," *J. Adv. Inf. Technol.*, vol. 15, no. 3, 2024.
- [11] O. Iparraguirre-Villanueva, V. Guevara-Ponce, O. Paredes, F. Sierra-Liñan, J. Zapata-Paulini, and M. Cabanillas-Carbonell, "Convolutional Neural Networks use Architecture InceptionV3," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, Jan. 2022, doi: 10.14569/IJACSA.2022.0130963.
- [12] Daniati Uki Eka Saputri, Nurul Khasanah, F. Aziz, and Taopik Hidayat, "Classification Using Optimized InceptionV3 Model," *J. Med. Informatics Technol.*, pp. 65–69, 2023, doi: 10.37034/medinftech.v1i3.14.
- [13] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, 2016, doi: 10.12962/j23373539.v5i1.15696.
- [14] H. Basri, P. Purnawansyah, H. Darwis, and F. Umar, "Klasifikasi Daun Herbal Menggunakan K-

- Nearest Neighbor dan Convolutional Neural Network dengan Ekstraksi Fourier Descriptor,” *J. Teknol. dan Manaj. Inform.*, vol. 9, no. 2, pp. 79–90, 2023, doi: 10.26905/jtmi.v9i2.10350.
- [15] D. Indra, H. M. Fadlillah, Kasman, L. B. Ilmawan, and H. Lahuddin, “Classification of good and damaged rice using convolutional neural network,” *Bull. Electr. Eng. Informatics*, vol. 11, no. 2, pp. 785–792, 2022, doi: 10.11591/eei.v11i2.3385.
- [16] Q. Yu, Y. Han, W. Lin, and X. Gao, “Detection and analysis of corrosion on coated metal surfaces using enhanced YOLO v5 algorithm for anti-corrosion performance evaluation,” *J. Mar. Sci. Eng.*, vol. 12, no. 7, p. 1090, 2024.
- [17] F. M. Talaat and H. ZainEldin, “An improved fire detection approach based on YOLO-v8 for smart cities,” *Neural Comput. Appl.*, vol. 35, no. 28, pp. 20939–20954, 2023.