

KLASIFIKASI KEDELAI GMO DAN NON-GMO MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK

Dhani Yogatama¹⁾, Supatman²⁾

^{1,2}Informatika, Universitas Mercu Buana Yogyakarta

Corresponding Author: ¹yogatamadhani93@gmail.com, ²supatman@mercubuna-yogya.ac.id

Article Info

Article history:

Received: April 29, 2025

Revised: May 15, 2025

Accepted: June 5, 2025

Published: June 30, 2025

Keywords:

Soybean Classification,
GMO Detection,
CNN,
Deep Learning,
Digital Image Processing

ABSTRACT

The rapid advancement of Genetically Modified Organisms (GMO) in agriculture raises concerns regarding food safety, labeling, and consumer protection, especially in soybean commodities. Due to the high visual similarity between GMO and non-GMO soybeans, traditional identification methods such as molecular testing are often impractical for real-time inspection. This research proposes a classification approach using Convolutional Neural Network (CNN) to automatically distinguish between GMO and non-GMO soybean seeds based on digital images. The dataset used consists of 1,000 soybean seed images, evenly divided between GMO and non-GMO categories, collected using a controlled imaging setup. The preprocessing stage involved cropping, resizing images to 128x128 pixels, and pixel normalization. The dataset was then split into a 70% training set, 10% validation set, and 20% test set to ensure robust model evaluation. The CNN model architecture includes convolutional, pooling, and dense layers, trained using the Adam optimizer and categorical crossentropy loss function. The evaluation results show that the model achieved a test accuracy of 99.00%, with high precision, recall, and F1-score for both classes. These findings demonstrate that CNN can be used to classify soybean seeds without manual feature extraction, offering a practical solution for quality control in agriculture and food processing industries.



This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY SA 4.0)

1. INTRODUCTION

Kedelai merupakan salah satu tanaman pangan yang memiliki peran penting dalam menunjang ketahanan pangan dan industri pengolahan makanan di Indonesia, dengan permintaan yang terus meningkat seiring pertumbuhan penduduk dan pendapatan per kapita [1][2]. Berbagai produk olahan berbasis kedelai seperti tempe, tahu, susu kedelai, serta makanan fermentasi lainnya telah menjadi bagian tak terpisahkan dari konsumsi masyarakat sehari-hari. Seiring dengan meningkatnya kebutuhan pangan, permintaan terhadap bahan baku kedelai juga mengalami peningkatan signifikan [3]. Untuk mengatasi tantangan produktivitas, kinerja optimal, dan ketahanan terhadap hama maupun cuaca ekstrem, penerapan teknologi rekayasa genetika dalam pengembangan varietas kedelai menjadi solusi yang banyak diadopsi. Hal ini memunculkan varietas baru berupa kedelai hasil rekayasa genetik atau yang dikenal sebagai Genetically Modified Organism (GMO) [4].

Secara fisik, biji kedelai GMO dan non-GMO memiliki kemiripan yang sangat tinggi, bahkan hampir tidak dapat dibedakan secara kasat mata [5]. Hal ini

menyulitkan proses identifikasi secara manual, khususnya dalam skala besar atau dalam sistem produksi dan distribusi modern yang menuntut kecepatan dan akurasi tinggi. Metode konvensional seperti pengujian molekuler berbasis PCR memang mampu memberikan hasil akurat, namun memiliki keterbatasan dari sisi efektivitas biaya, waktu, dan kebutuhan tenaga ahli laboratorium. Oleh karena itu, pengembangan sistem klasifikasi otomatis berbasis visual dengan dukungan teknologi digital menjadi solusi yang menjanjikan untuk menyederhanakan proses identifikasi dan klasifikasi kedelai secara real-time [6].

Perkembangan teknologi informasi dan kecerdasan buatan, khususnya dalam bidang pengolahan citra digital, telah membuka peluang luas dalam penyelesaian berbagai permasalahan klasifikasi visual. Salah satu metode yang saat ini menempati posisi sentral dalam teknologi pengenalan pola visual adalah Convolutional Neural Network (CNN) [7]. CNN merupakan arsitektur deep learning yang secara khusus dirancang untuk mengolah data citra melalui proses pembelajaran fitur secara bertahap dan otomatis. Tidak seperti pendekatan klasik yang

memerlukan desain fitur manual dan sering kali bergantung pada intuisi manusia dalam menentukan parameter visual penting, CNN dapat mengekstraksi pola kompleks dalam data visual tanpa intervensi eksplisit. Arsitektur CNN tersusun atas lapisan konvolusi, pooling, dan fully connected yang bekerja secara hierarkis untuk mendeteksi dan menggabungkan fitur-fitur penting dari citra [8].

Berbagai studi sebelumnya telah menunjukkan bahwa CNN mampu memberikan performa klasifikasi tinggi dalam konteks agrikultur. CNN telah berhasil digunakan untuk mengidentifikasi tingkat kematangan buah, klasifikasi jenis daun, pendeteksian penyakit tanaman, serta penentuan mutu produk hasil panen. Misalnya, penelitian oleh Mas'ud Effendi, Naufal Hilmi Ramadhan dan Arif Hidayat (2023) dalam Image-based Quality Identification of Black Soybean (Glycine soja) Using Convolutional Neural Network menghasilkan akurasi sebesar 90,18% [9], sementara Amanda Prawita Ningrum, Sri Winarno dan Vincentius Praskatama (2024) dalam Klasifikasi Kualitas Biji Kedelai Menggunakan Transfer Learning Convolutional Neural Network Dan SMOTE mencapai akurasi hingga 92,42% [10]. Studi-studi ini membuktikan bahwa CNN mampu beradaptasi dengan variasi visual alami dan menunjukkan ketahanan terhadap kondisi data yang kompleks, membuatnya sangat tepat untuk diadopsi dalam klasifikasi citra kedelai. Terlebih lagi, pendekatan CNN secara end-to-end memungkinkan implementasi praktis dalam sistem nyata seperti kamera inspeksi otomatis, aplikasi berbasis smartphone, maupun perangkat edge computing yang terhubung dengan sistem pemantauan berbasis Internet of Things (IoT) [11].

Penelitian ini secara khusus memfokuskan pada penerapan CNN dalam mengklasifikasikan citra biji kedelai GMO dan non-GMO menggunakan dataset primer yang diperoleh dari proses dokumentasi visual langsung. Model CNN dilatih untuk mengenali pola visual unik yang mungkin tersembunyi bagi penglihatan manusia namun dapat dipelajari oleh mesin, seperti perbedaan tekstur mikro, pencahayaan, atau distribusi warna permukaan biji. Dalam penelitian ini, variabel independen adalah citra digital dari biji kedelai, sedangkan variabel dependen adalah hasil klasifikasi yang dihasilkan oleh model CNN dalam dua kategori, yaitu GMO dan non-GMO [12]. Sistem klasifikasi ini dibangun tanpa tahapan ekstraksi fitur manual maupun segmentasi awal, sehingga mempercepat proses dan meminimalkan risiko kesalahan akibat intervensi manusia.

Penelitian ini diharapkan memberikan kontribusi signifikan dalam pengembangan sistem klasifikasi visual yang tidak hanya terukur, tetapi juga mampu bekerja secara otomatis dan adaptif terhadap variasi data. Nilai kebaruan dari penelitian ini terletak pada penerapan langsung CNN terhadap data citra biji kedelai yang bersifat primer, tanpa pengolahan tambahan, serta pendekatannya yang terfokus pada

klasifikasi berbasis pembelajaran mesin tingkat lanjut. Dengan demikian, penelitian ini tidak hanya memberikan solusi praktis terhadap permasalahan klasifikasi kedelai GMO dan non-GMO, tetapi juga memperkaya referensi akademik dalam bidang informatika pertanian, pengolahan citra digital, dan penerapan artificial intelligence dalam sistem produksi pertanian cerdas berbasis data (data-driven smart agriculture).

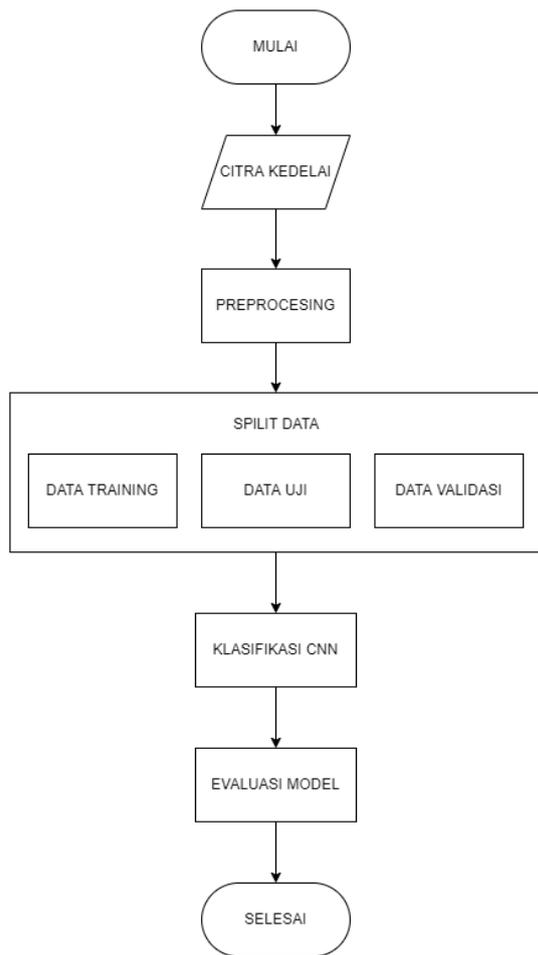
2. MATERIALS AND METHODS

2.1. Materials

Kedelai (*Glycine max*) merupakan tanaman leguminosa yang memiliki nilai ekonomis dan nutrisi tinggi, serta berperan penting sebagai sumber utama protein nabati dalam konsumsi masyarakat Indonesia [13]. Seiring dengan meningkatnya permintaan dan kebutuhan akan produktivitas tinggi, varietas kedelai telah mengalami pengembangan melalui teknik rekayasa genetika untuk menghasilkan kedelai GMO (Genetically Modified Organism) [14]. Varietas ini biasanya memiliki keunggulan dalam hal daya tahan terhadap hama, kecepatan pertumbuhan, serta hasil panen yang lebih tinggi. Oleh karena itu, identifikasi berbasis visual dengan bantuan teknologi digital menjadi penting untuk mendukung sistem klasifikasi yang terukur dan akurat. Dalam konteks penelitian ini, citra biji kedelai GMO dan non-GMO digunakan sebagai objek utama untuk pelatihan dan pengujian model klasifikasi berbasis Convolutional Neural Network (CNN).

2.2. Metodologi

Pada penelitian ini dilakukan beberapa tahapan sesuai tahapan metodologi yang ditunjukkan pada Gambar 1. Tahapan dimulai dari pengumpulan dataset berupa citra biji kedelai GMO dan non-GMO. Perangkat keras yang digunakan dalam proses pelatihan model adalah laptop dengan spesifikasi prosesor AMD Ryzen 5 5500U, sedangkan perangkat lunak yang digunakan adalah platform Google Colab berbasis cloud computing. Pemrograman dilakukan menggunakan bahasa Python dengan bantuan pustaka TensorFlow dan Keras.



Gambar 1. Diagram Alur Penelitian

2.2.1 Dataset

Penelitian ini menggunakan dataset yang terdiri dari citra kedelai GMO dan non-GMO. Data diperoleh melalui proses pengambilan gambar langsung menggunakan Kamera Sony A6000 dengan alat bantu tripod.

Proses akuisisi data dilakukan dalam kondisi pencahayaan lampu LED 12W, selanjutnya citra akan disimpan dalam format .jpg. Total dataset yang digunakan dalam penelitian ini terdiri dari 500 citra kedelai GMO dan 500 citra kedelai non-GMO. Contoh hasil akuisisi ditunjukkan pada Tabel 1.

Tabel 1: Hasil Akuisisi Citra Biji Kedelai GMO Dan Non-GMO Menggunakan Kamera Sony A6000

GMO	Non-GMO
	



Meski pencahayaan dan posisi kamera yang telah dikondisikan dengan lampu LED 12W dan alat bantu tripod, terdapat kemungkinan bias akibat bayangan atau perbedaan sudut pengambilan gambar. Variasi ini dapat mempengaruhi model saat berhadapan dengan kondisi nyata di luar lingkungan uji.

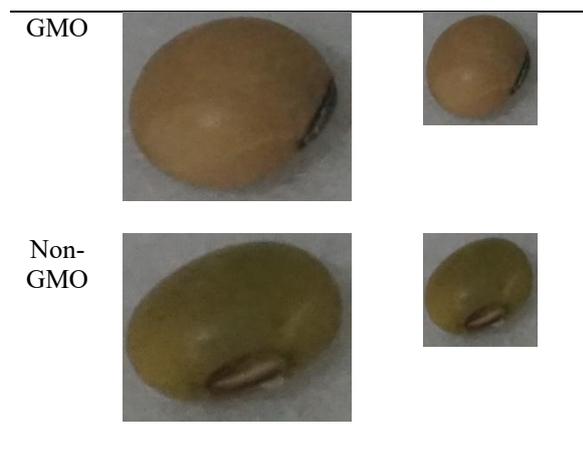
2.2.2. Pre-Processing

Preprocessing dilakukan untuk menyiapkan data pelatihan dan pengujian[15], Tahapan pre-processing yang dilakukan dalam penelitian ini:

- 1) Cropping : Proses pemotongan gambar yang bertujuan untuk memfokuskan perhatian pada elemen utama citra, yaitu kedelai GMO dan kedelai non-GMO, dengan cara menghilangkan bagian yang tidak relevan guna memperoleh warna dan tekstur yang signifikan. Cropping ini dilakukan secara manual dan untuk menunjukkan objek kedelai sebagai elemen utama.
- 2) Resize : Proses untuk mengubah ukuran dimensi sebuah citra yang bertujuan untuk memperkecil atau memperbesar citra sesuai kebutuhan. Pada penelitian ini citra kedelai GMO dan kedelai non-GMO di-resize ke ukuran 128×128 piksel. Resizing ini bertujuan agar mempercepat proses pelatihan dan pengujian sistem serta menjaga konsistensi ukuran citra.

Tabel 2: Hasil Cropping dan Resize (128×128)

Jenis	Cropping	Resize
-------	----------	--------



2.2.3. Split Data

Pada tahap ini, data citra kedelai yang telah melalui proses pra-pemrosesan dibagi menjadi tiga subset utama, yaitu data pelatihan (training set), data uji (testing set) dan data validasi. Pembagian ini merupakan langkah krusial dalam proses pengembangan model pembelajaran mesin, karena bertujuan untuk memastikan bahwa model tidak hanya mampu mengenali pola dari data yang telah dilatih, tetapi juga mampu melakukan generalisasi terhadap data baru yang belum pernah ditemui sebelumnya. Pada penelitian ini, pembagian data dilakukan secara acak dengan menggunakan fungsi scikit-learn, dengan proporsi 70% data digunakan sebagai data pelatihan, 10% sebagai data uji dan 20% sebagai data validasi. Proporsi ini dipilih berdasarkan praktik umum dalam penelitian pembelajaran mesin yang mempertimbangkan keseimbangan antara jumlah data yang cukup untuk pelatihan dan data yang memadai untuk evaluasi performa model.

Data pelatihan digunakan dalam proses pelatihan model Convolutional Neural Network (CNN), di mana model akan mempelajari fitur-fitur representatif dari citra kedelai. Sementara itu, data uji berperan sebagai acuan independen untuk mengukur akurasi dan kemampuan generalisasi model. Pemisahan data pelatihan dan data uji dilakukan secara eksplisit guna menghindari potensi kebocoran data, sehingga hasil evaluasi model tetap valid dan dapat diandalkan. Selain itu, pembagian dilakukan secara acak untuk memastikan bahwa distribusi kelas pada kedua subset tetap proporsional antara kelas GMO dan non-GMO. Hal ini penting untuk menjaga keseimbangan data, karena ketimpangan distribusi kelas dapat menyebabkan bias dalam pelatihan dan menurunkan kinerja model secara keseluruhan.

2.2.4. CNN

Pada tahap klasifikasi, model Convolutional Neural Network (CNN) digunakan untuk membedakan antara citra biji kedelai jenis GMO dan non-GMO. Berbeda dengan metode instance-based

learning seperti KNN, CNN mempelajari pola dan ciri khas penting dari data citra melalui proses pelatihan yang melibatkan propagasi maju (forward propagation) dan pembaruan bobot menggunakan backpropagation.

Dalam penelitian ini, arsitektur CNN dibangun dengan beberapa lapisan konvolusi (Conv2D) dan pooling (MaxPooling2D) yang diikuti oleh lapisan flatten dan dense untuk klasifikasi akhir. Fungsi aktivasi yang digunakan pada lapisan konvolusi adalah ReLU (Rectified Linear Unit), sedangkan pada lapisan output digunakan fungsi softmax untuk menghasilkan probabilitas dari dua kelas (GMO dan non-GMO). Untuk mencegah overfitting, juga disisipkan lapisan dropout 0.3. Model sequential dapat dilihat pada Tabel 3.

Tabel 3: Arsitektur CNN

Layer (Type)	Output Shape	Parameter
Conv2d	(None, 128, 128, 16)	448
Max_pooling2d	(None, 64, 64, 16)	0
Conv2d_1	(None, 64, 64, 32)	4,640
Max_pooling2d_1	(None, 64, 64, 32)	0
Flatten	(None, 32768)	0
Dense	(None, 64)	2,097,216
Dropout	(None, 64)	0
Dense_1	(None, 2)	130

Sebelum pelatihan dilakukan, citra dikonversi ke ukuran seragam dan dinormalisasi ke rentang [0,1] dengan cara membagi nilai piksel dengan 255. Selanjutnya, dataset dibagi menjadi dua bagian, yaitu 70% data untuk pelatihan (training), 10% untuk pengujian (testing) dan 20% untuk validasi. Pembagian ini dilakukan secara acak namun terkontrol, sehingga distribusi kelas GMO dan non-GMO tetap proporsional pada kedua subset. Model dilatih dengan menggunakan fungsi loss categorical_crossentropy dan algoritma optimasi Adam, dengan beberapa parameter callback seperti EarlyStopping, ModelCheckpoint, dan ReduceLROnPlateau untuk meningkatkan kinerja dan stabilitas pelatihan.

Selama pelatihan, model CNN secara bertahap mempelajari fitur yang terdapat pada masing-masing kelas citra. Tidak seperti KNN yang menghitung jarak antar data, CNN membangun representasi hierarkis dari fitur citra yang kemudian digunakan oleh lapisan fully connected untuk memutuskan klasifikasi akhir berdasarkan pola-pola yang telah dipelajari. Dengan pendekatan ini, CNN diharapkan mampu mengklasifikasikan citra biji kedelai dengan akurasi yang tinggi dan ketahanan terhadap variasi visual pada data masukan.

Struktur arsitektur CNN yang digunakan dalam penelitian ini masih bersifat dasar dan belum dibandingkan dengan arsitektur lain yang lebih kompleks seperti ResNet atau pendekatan transfer learning. Hal ini menjadi salah satu keterbatasan dalam penelitian ini, mengingat model yang lebih dalam atau pretrained network berpotensi menghasilkan representasi fitur yang lebih kaya dan dapat meningkatkan kinerja klasifikasi. Oleh karena itu, eksperimen pembandingan dengan arsitektur alternatif akan menjadi fokus penting dalam pengembangan lanjutan, guna mengevaluasi secara lebih menyeluruh keandalan pendekatan yang diusulkan.

2.2.5. Evaluasi Model

Evaluasi kinerja model klasifikasi dilakukan untuk mengukur sejauh mana model Convolutional Neural Network (CNN) mampu mengklasifikasikan citra biji kedelai ke dalam dua kelas, yaitu GMO dan non-GMO. Penilaian performa model dilakukan dengan menghitung sejumlah metrik evaluasi, di antaranya adalah akurasi (accuracy), presisi (precision), recall, dan F1-score, serta dilengkapi dengan visualisasi menggunakan confusion matrix.

Akurasi (accuracy) menunjukkan proporsi jumlah prediksi yang benar terhadap keseluruhan data uji, sedangkan presisi (precision) mengukur ketepatan model dalam memprediksi kelas positif (GMO), yaitu berapa banyak dari prediksi GMO yang benar-benar GMO. Sementara itu, recall mengukur sejauh mana model mampu mendeteksi seluruh data GMO yang sebenarnya, dan F1-score merupakan rata-rata harmonis dari precision dan recall yang berguna dalam situasi distribusi kelas yang tidak seimbang. Rumus masing-masing metrik dituliskan sebagai berikut:

$$Akurasi = \left(\frac{TP + TN}{TP + TN + FP + FN} \right) \times 100\%$$

$$Recall = \frac{TP}{TP + FN}$$

$$Presisi = \frac{TP}{TP + FP}$$

$$F1 - score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

Keterangan:

- TP (True Positive): data GMO yang terklasifikasi sebagai GMO.
- TN (True Negative): data non-GMO yang terklasifikasi sebagai non-GMO.
- FP (False Positive): data non-GMO yang salah diklasifikasikan sebagai GMO.
- FN (False Negative): data GMO yang salah diklasifikasikan sebagai non-GMO.

Selain evaluasi numerik, dilakukan pula visualisasi hasil prediksi model menggunakan confusion matrix. Confusion matrix memberikan informasi rinci mengenai performa model dalam mengenali masing-masing kelas, termasuk kesalahan klasifikasi dan proporsi prediksi yang tepat.

Visualisasi ini sangat berguna dalam mengidentifikasi kelemahan model, terutama jika terdapat ketidakseimbangan distribusi antar kelas atau pola kesalahan klasifikasi tertentu. Kombinasi metrik evaluasi dan confusion matrix memungkinkan analisis performa model CNN secara menyeluruh, sehingga efektivitas model dalam klasifikasi citra biji kedelai dapat dinilai secara objektif.

Perlu dicatat bahwa validasi dalam penelitian ini hanya dilakukan pada dataset yang berasal dari satu proses akuisisi dengan konfigurasi yang sama. Untuk menguji kemampuan model dalam menghadapi variasi nyata di lingkungan berbeda, evaluasi eksternal menggunakan data dari sumber lain sangat diperlukan. Hal ini akan membantu memastikan bahwa model tidak hanya mampu menghafal pola, tetapi juga mampu beradaptasi terhadap perubahan kondisi pencahayaan, latar belakang, atau jenis varietas yang belum dilatih.

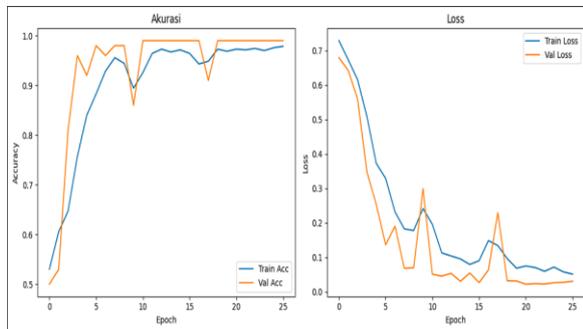
3. RESULTS AND DISCUSSION

Pada bagian ini disajikan hasil dari proses pelatihan dan pengujian model Convolutional Neural Network (CNN) yang digunakan untuk mengklasifikasikan citra biji kedelai ke dalam dua kategori, yaitu GMO dan non-GMO. Hasil penelitian ditampilkan dalam bentuk grafik akurasi dan loss selama pelatihan, confusion matrix, serta visualisasi hasil prediksi pada data uji. Selain itu, dilakukan analisis terhadap performa model berdasarkan metrik evaluasi seperti akurasi, presisi, recall, dan F1-score. Diskusi difokuskan pada interpretasi hasil evaluasi model, efektivitas arsitektur CNN dalam mengenali perbedaan visual antara biji kedelai GMO dan non-GMO, serta potensi penerapan model dalam sistem klasifikasi otomatis di bidang pertanian berbasis citra digital.

3.1. Hasil Pelatihan Model CNN

Model CNN yang digunakan dalam penelitian ini dibangun menggunakan beberapa lapisan konvolusi dan pooling, serta dilengkapi dengan lapisan fully connected pada bagian akhir untuk melakukan klasifikasi citra biji kedelai ke dalam kelas GMO dan non-GMO. Selama proses pelatihan, digunakan fungsi aktivasi ReLU pada setiap lapisan konvolusi dan fungsi aktivasi Softmax pada lapisan output. Proses pelatihan dilakukan menggunakan optimizer Adam dan fungsi loss categorical crossentropy, dengan bantuan callback seperti EarlyStopping, ModelCheckpoint, dan ReduceLROnPlateau untuk meningkatkan stabilitas dan efektivitas pelatihan.

Model dilatih menggunakan 70% dari total dataset (700 citra) sebagai data pelatihan, 20% (200 citra) sebagai data uji dan 10% (100 citra) sebagai data validasi. Pelatihan dilakukan selama 100 epoch dengan ukuran batch sebesar 32. Selama proses pelatihan, akurasi dan loss pada data pelatihan dan validasi dicatat untuk dianalisis lebih lanjut pada grafik dibawah ini.



Gambar 2. Grafik Kurva akurasi dan loss selama pelatihan dan validasi model CNN.

Hasil pelatihan menunjukkan bahwa model mengalami konvergensi yang stabil setelah beberapa epoch, dengan tren akurasi yang meningkat dan nilai loss yang menurun seiring bertambahnya jumlah epoch. Grafik akurasi dan loss dari proses pelatihan dan validasi dapat dilihat pada Gambar 2. Berdasarkan grafik tersebut, dapat dilihat bahwa model berhasil belajar secara efektif dari data pelatihan tanpa mengalami overfitting yang signifikan, ditunjukkan oleh kesenjangan yang kecil antara kurva akurasi dan loss pada data pelatihan dan validasi.

3.2. Evaluasi Kinerja Model

Setelah proses pelatihan selesai, model CNN diuji menggunakan data uji sebanyak 200 citra yang terdiri dari 100 gambar biji kedelai GMO dan 100 gambar non-GMO. Berdasarkan hasil pengujian, model CNN berhasil mencapai akurasi sebesar 99,00% pada data uji. Nilai ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat tinggi dan konsisten dalam mengenali pola visual dari biji kedelai.

Selain akurasi, evaluasi performa model juga dilakukan dengan menghitung presisi, recall, dan F1-score untuk masing-masing kelas. Hasil perhitungan metrik evaluasi secara lengkap dapat dilihat pada Tabel 4, yang menunjukkan bahwa model mampu melakukan klasifikasi dengan presisi dan sensitivitas yang tinggi pada kedua kelas.

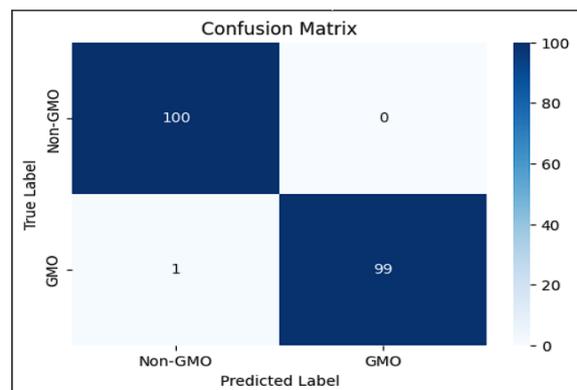
Tabel 4: Hasil Evaluasi Model CNN Terhadap Data Uji.

kategori	precision	recall	F1-score
GMO	0.99	1.00	1.00
Non GMO	1.00	0.99	0.99

Macro avg	1.00	0.99	0.99
Weight avg	1.00	0.99	0.99
accuracy	0.99		

3.3. Visualisasi Hasil Prediksi

Untuk memperjelas performa klasifikasi model, digunakan confusion matrix yang divisualisasikan pada Gambar 3. Confusion matrix ini memperlihatkan bahwa sebagian besar prediksi model berada pada diagonal utama, yang menunjukkan banyaknya jumlah klasifikasi yang benar.



Gambar 3. Hasil Confusion Matrix

Terdapat sejumlah kecil kesalahan klasifikasi, yang terjadi ketika ciri khas visual antara biji GMO dan non-GMO sangat mirip atau terdapat gangguan pencahayaan pada citra. Hasil ini menunjukkan bahwa model CNN memiliki performa yang sangat baik dalam membedakan biji kedelai GMO dan non-GMO berdasarkan citra digital. Evaluasi numerik yang diperoleh memperkuat kemampuan model dalam mengenali fitur-fitur pembeda yang sesuai.

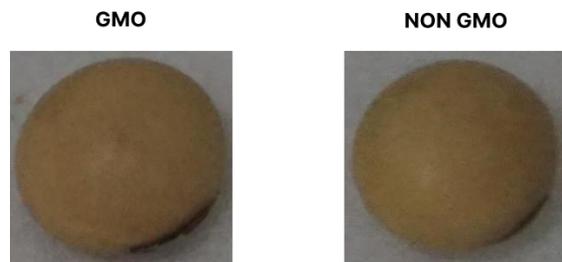
3.4. Pembahasan

Hasil klasifikasi yang diperoleh dari model CNN menunjukkan performa yang sangat tinggi, dengan akurasi mencapai 99,00% pada data uji. Nilai tersebut menunjukkan bahwa CNN mampu mengenali dan membedakan pola visual yang penting antara biji kedelai GMO dan non-GMO secara akurat. Kinerja tinggi ini dicapai tanpa memerlukan proses ekstraksi fitur manual, yang biasanya membutuhkan pengetahuan domain dan sering bersifat subjektif.

Jika dibandingkan dengan studi oleh Effendi et al. (2023) yang mencapai akurasi 90,18% dan Ningrum et al. (2024) yang memperoleh 92,42%, maka akurasi 99,00% dalam penelitian ini menunjukkan keunggulan dalam proses pembelajaran fitur langsung dari citra primer, meskipun faktor seperti jenis kamera dan latar belakang juga turut berpengaruh.

Meskipun hasil yang diperoleh sangat tinggi, terdapat beberapa kesalahan klasifikasi yang tercatat pada confusion matrix. Kesalahan ini kemungkinan

disebabkan oleh kualitas citra yang kurang optimal, seperti pencahayaan yang tidak merata, bayangan pada permukaan biji, atau posisi pengambilan gambar yang kurang konsisten. Selain itu, beberapa biji GMO dan non-GMO memang memiliki fitur visual yang sangat mirip, seperti pada gambar 4.



Gambar 4. Kedelai Dengan Visual Yang Hampir Mirip

Gambar tersebut menunjukkan bahwa secara visual, perbedaan antara dua kelas memang dapat sangat tipis, terutama jika terdapat variasi kecil pada pencahayaan atau tekstur permukaan, sehingga berpotensi membingungkan baik bagi manusia maupun model.

Sistem klasifikasi ini berpotensi untuk diintegrasikan ke dalam perangkat keras ringan seperti kamera berbasis edge computing yang ditempatkan pada jalur sortir di gudang distribusi atau stasiun inspeksi hasil panen. Selain itu, model juga dapat ditanamkan dalam aplikasi mobile yang digunakan petani atau pengepul untuk melakukan klasifikasi visual secara langsung di lapangan.

4. CONCLUSION

Penelitian ini telah berhasil menerapkan model Convolutional Neural Network (CNN) untuk melakukan klasifikasi citra biji kedelai ke dalam dua kategori, yaitu GMO dan non-GMO, berdasarkan data citra digital yang diperoleh secara langsung. Model CNN yang dibangun mampu mencapai akurasi sebesar 99,00% pada data uji, yang menunjukkan efektivitas dan keandalan metode ini dalam mengenali pola visual yang membedakan kedua jenis biji kedelai tersebut.

Dengan proses pelatihan yang dilakukan secara end-to-end tanpa tahapan ekstraksi fitur manual, CNN terbukti mampu mengekstraksi fitur secara otomatis dan melakukan klasifikasi secara akurat. Hasil ini menegaskan bahwa pendekatan berbasis deep learning sangat potensial untuk diterapkan dalam sistem klasifikasi visual di sektor pertanian, khususnya dalam pengawasan mutu dan identifikasi produk berbasis rekayasa genetika.

Untuk pengembangan selanjutnya, penelitian ini dapat diperluas dengan eksplorasi terhadap arsitektur CNN yang lebih dalam atau pemanfaatan transfer learning juga dapat dipertimbangkan untuk mengoptimalkan kinerja sistem klasifikasi secara keseluruhan.

ACKNOWLEDGEMENTS

Syukur tak terhingga penulis panjatkan kepada Tuhan Yang Maha Esa atas kekuatan dan pemahaman yang dianugerahkan sepanjang penelitian ini. Penulis juga berterima kasih kepada orang tua, dosen, dan teman-teman, yang sumbangsihnya berupa dukungan, pandangan, serta saran sangat berarti dalam mematangkan ide, memperdalam analisis, dan menyempurnakan karya tulis ini.

REFERENCES

- [1] L. F. Pusposari, "Analisis Permintaan Kedelai Di Indonesia," *J-PIPS (Jurnal Pendidik. Ilmu Pengetah. Sos.*, vol. 1, no. 1, p. 77, 2014, doi: 10.18860/j-pips.v1i1.6813.
- [2] A. R. Ruvananda and M. Taufiq, "Analisis faktor-faktor yang mempengaruhi impor beras di Indonesia," *Kinerja*, vol. 19, no. 2, pp. 195–204, 2022, doi: 10.30872/jkin.v19i2.10924.
- [3] S. A. Pramono, "Inovasi Potensi Pangan Kacang Kedelai: Dari Olahan Produk Hingga Pemasaran Online," *J. Atma Inovasia*, vol. 1, no. 3, pp. 402–408, 2021, doi: 10.24002/jai.v1i3.3983.
- [4] V. Agustiarini and D. Permata Wijaya, "Jurnal Penelitian Sains," *J. Penelit. Sains*, vol. 21, no. 3, pp. 163–167, 2021.
- [5] A. M. Ulfa, "Identification of GMO And NON-GMO Tempeh Images Using The Convolutional Neural Network," vol. 17, no. 1, pp. 14–24, 2024.
- [6] E. R. Septiana, F. A. Fiolana, and D. Erwanto, "Klasifikasi Kualitas Citra Kedelai Hitam (Malika) Menggunakan Metode K-Nearest Neighbor," *JEECOM J. Electr. Eng. Comput.*, vol. 4, no. 2, pp. 79–86, 2022, doi: 10.33650/jeeecom.v4i2.4469.
- [7] D. Sharma and A. Jain, "A CNN-based approach for quality grading of soybean seeds," *J. Food Qual.*, vol. 2021, pp. 1–9, 2021, doi: 10.1155/2021/6693203.
- [8] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, pp. 87–92, 2021, doi: 10.30591/jpit.v6i2.2802.
- [9] M. Effendi, N. H. Ramadhan, and A. Hidayat, "Image-based Quality Identification of Black Soybean (Glycine soja) Using Convolutional Neural Network," *Ind. J. Teknol. dan Manaj. Agroindustri*, vol. 12, no. 1, pp. 73–88, 2023, doi: 10.21776/ub.industria.2023.012.01.7.
- [10] A. P. Ningrum, S. Winarno, and V. Praskatama, "JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST) Klasifikasi Kualitas Biji Kedelai Menggunakan Transfer Learning Convolutional Neural Network Dan SMOTE," vol. 5, no. 2, pp. 155–164, 2024.
- [11] L. S. Pieters, U. Pradita, S. B. Park, and K. Tangerang, "DEVELOPMENT OF AUTOMATIC WASTE CLASSIFICATION SYSTEM USING CNN BASED DEEP LEARNING TO SUPPORT SMART WASTE MANAGEMENT OTOMATIS MENGGUNAKAN DEEP LEARNING BERBASIS," vol. 10, no. 1, pp. 214–224, 2025.
- [12] S. P. Backar, P. Purnawansyah, H. Darwis, and W. Astuti, "Hybrid Fourier Descriptor Naïve Bayes dan CNN pada Klasifikasi Daun Herbal," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 126–133, 2023, doi: 10.30591/jpit.v8i2.5186.
- [13] E. Triyana, T. Hadi, and W. Atmaja, "Jurnal Biologi Tropis Effectiveness of Elephant Grass (Pennisetum purpureum) Green Fertilizer on the Growth of Soybean Plants (Glycine max L . Merrill)," 2024.
- [14] R. D. Isna, Hapsah, and A. E. Yulia, "Penerapan Prinsip Etika Lingkungan Pada Teknologi Rekayasa Genetik Tanaman Dan Regulasi Keamanan Produk Rekayasa Genetika," *J. Senpling Multidisiplin Indones.*, vol. 1, no. 1, pp. 8–19, 2023, [Online]. Available: <http://senpling.pelantarpress.co.id/8>
- [15] J. E. Widayana and S. Budi, "The Effect of Preprocessing on

- the Classification of Diabetic Retinopathy with the Transfer Learning Convolutional Neural Network Approach,” *J. Tek. Inform. dan Sist. Inf.*, vol. 7, no. 1, pp. 110–124, 2021.
- [16] P. A. Nugroho, I. Fenriana, and R. Arijanto, “Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia,” *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [17] M. Rijal, A. M. Yani, and A. Rahman, “Deteksi Citra Daun untuk Klasifikasi Penyakit Padi menggunakan Pendekatan Deep Learning dengan Model CNN,” *J. Teknol. Terpadu*, vol. 10, no. 1, pp. 56–62, 2024, doi: 10.54914/jtt.v10i1.1224.
- [18] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, “Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network,” *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 2, p. 259, 2021, doi: 10.35314/isi.v6i2.2104
- [19] N. Sitohang, “Jurnal Sains Informatika Terapan (JSIT),” *Penerapan Data Min. Untuk Peringatan Dini Banjir Menggunakan Metod. Klastering K-Means*, vol. 2, no. 1, pp. 16–20, 2023.
- [20] K. Yudiono, “Peningkatan Daya Saing Kedelai Lokal Terhadap Kedelai Impor Sebagai Bahan Baku Tempe Melalui Pemetaan Fisiko-Kimia,” *Agrointek*, vol. 14, no. 1, pp. 57–66, 2020, doi: 10.21107/agrointek.v14i1.6311.