

## Penerapan *Deep Learning* untuk Klasifikasi Buah Berdasarkan Citra dengan Metode *Convolutional Neural Networks*

Dede Wulan Rahayu<sup>1</sup>, David Setiadi<sup>2</sup>, Dwi Yuniarto<sup>3</sup>

<sup>1,2,3</sup> Fakultas Teknologi Informasi, Universitas Sebelas April, Sumedang, Indonesia

### Article Info

#### Article history:

Received December 26, 2024  
 Revised December 27, 2024  
 Accepted December 27, 2024

#### Kata Kunci:

Deep Learning,  
 Convolutional Neural  
 Networks,  
 Klasifikasi buah,  
 Citra digital,

#### Keywords:

*Deep Learning,*  
*Convolutional Neural*  
*Networks,*  
*Fruit classification,*  
*Digital image,*

### ABSTRAK

Peningkatan efisiensi dalam pemilihan dan klasifikasi buah menjadi tantangan utama dalam industri pangan. Proses manual yang digunakan selama ini memakan waktu dan rentan terhadap kesalahan manusia. Penelitian ini mengembangkan sistem otomatis untuk klasifikasi buah menggunakan Convolutional Neural Networks (CNN) yang mampu mengenali berbagai jenis buah melalui citra digital. CNN dipilih karena kemampuannya dalam mengekstraksi fitur secara otomatis dan mengidentifikasi pola visual bahkan dalam kondisi pencahayaan dan variasi bentuk yang berbeda. Model yang dikembangkan menunjukkan hasil yang sangat baik, dengan akurasi lebih dari 96% pada data pelatihan dan validasi. Selain itu, model ini juga mencapai nilai precision, recall, dan F1-score yang hampir sempurna, mendekati 1.0, untuk setiap kelas buah yang diuji. Temuan ini menunjukkan bahwa CNN merupakan pendekatan yang sangat efektif untuk meningkatkan kecepatan dan akurasi dalam klasifikasi buah yang dapat diimplementasikan untuk meningkatkan efisiensi dalam industri pangan. Penelitian ini tidak hanya memberikan solusi untuk mengatasi kendala dalam proses pemilihan buah secara manual, tetapi juga membuka peluang untuk penerapan teknologi serupa dalam sektor pertanian dan distribusi pangan lainnya, sehingga dapat meningkatkan produktivitas dan kualitas hasil pertanian secara keseluruhan. Dengan demikian, sistem klasifikasi otomatis ini berpotensi menjadi alat yang berharga dalam mendukung keberlanjutan dan efisiensi industri pangan di masa depan.

### ABSTRACT

*Improving efficiency in the selection and classification of fruits is a significant challenge in the food industry. The manual processes currently in use are time-consuming and prone to human error. This research develops an automated system for fruit classification using Convolutional Neural Networks (CNN) that can recognize various types of fruits through digital images. CNNs were selected for their ability to automatically extract features and identify visual patterns under varying lighting conditions and shapes. The developed model achieves over 96% accuracy on both training and validation data, with precision, recall, and F1-score values approaching 1.0 for each tested fruit class. These findings indicate that CNNs are an effective approach for enhancing the speed and accuracy of fruit classification, which can improve efficiency in the food industry. This research not only addresses challenges in manual fruit selection but also opens opportunities for similar technology applications in agriculture and food distribution, enhancing productivity and quality. Thus, this automated classification system has the potential to become a valuable tool in supporting sustainability and efficiency in the food industry.*

This is an open access article under the [CC BY](https://creativecommons.org/licenses/by/4.0/) license



**Corresponding Author:**

Dede Wulan Rahayu  
Fakultas Teknologi Informasi, Universitas Sebelas April  
Sumedang, Indonesia  
Email: dedewulanrahayu@gmail.com

## 1. PENDAHULUAN

Perkembangan teknologi dalam bidang pertanian dan distribusi pangan telah membawa dampak signifikan terhadap efisiensi dan kualitas proses yang terjadi dalam rantai pasokan makanan [1]. Salah satu tantangan utama yang dihadapi oleh sektor ini adalah pengelolaan dan pemilihan buah-buahan yang cepat, akurat, dan efisien [2]. Selama ini proses tersebut banyak dilakukan secara manual, memerlukan waktu yang cukup lama dan sangat bergantung pada keterampilan serta pengalaman pekerja [3]. Pemilihan buah yang kurang tepat dapat berdampak pada kualitas produk akhir, menyebabkan kerugian dalam hal pemborosan atau penurunan kualitas.

Dengan meningkatnya permintaan pasar dan kompleksitas dalam rantai pasokan ada kebutuhan mendesak untuk mengimplementasikan sistem otomatis yang dapat mempercepat dan meningkatkan akurasi dalam proses pemilihan dan klasifikasi [4]. Penggunaan teknologi yang dapat membantu dalam identifikasi buah secara otomatis akan memberikan banyak keuntungan, termasuk mengurangi ketergantungan pada tenaga kerja manusia, mempercepat proses pemilihan, dan mengurangi kemungkinan kesalahan manusia.

Salah satu teknologi yang memiliki potensi besar dalam mengatasi masalah ini adalah Convolutional Neural Networks. CNN merupakan salah satu arsitektur dalam deep learning yang telah banyak digunakan dalam pengolahan citra [5]. CNN memiliki kemampuan untuk mengekstraksi fitur-fitur penting dalam gambar secara otomatis dan sangat efektif dalam mengenali pola visual yang ada pada citra [6]. Keunggulan utama dari CNN adalah kemampuannya untuk belajar dari data, menyesuaikan bobot dan parameter model berdasarkan pola yang ditemukan dalam citra, tanpa memerlukan fitur manual yang rumit. Dengan demikian, CNN dapat mengklasifikasikan jenis buah berdasarkan gambar secara lebih cepat dan akurat, meskipun terdapat variasi dalam bentuk, warna, dan kondisi pencahayaan gambar yang berbeda [7].

Beberapa studi sebelumnya telah mengkaji penerapan deep learning dalam mengidentifikasi citra dengan menggunakan convolutional neural network (CNN). Sebagai contoh, penelitian yang dilakukan oleh Sarirtul Ilahiyah dan Agung Nilogiri menggunakan 2000 citra daun, yang menghasilkan tingkat akurasi sebesar 85% [8]. Penelitian lain yang relevan mengaplikasikan deep learning juga dilakukan oleh Al-Shawwa Mohammed O tahun 2019 melakukan klasifikasi buah apel menggunakan deep learning dengan arsitektur jaringan sendiri mendapatkan hasil akurasi training 99.99% dan testing 100% [9]. Selain itu, Penelitian yang dilakukan oleh Juan M. Ponce memfokuskan pada klasifikasi jenis buah zaitun dengan menggunakan beberapa model pretrained, seperti AlexNet, InceptionResNetV2, InceptionV1, InceptionV3, ResNet50, dan ResNet101. Hasil penelitian tersebut menunjukkan akurasi yang bervariasi antara 89% hingga 95% untuk masing-masing model. Data yang digunakan dalam penelitian ini bersifat pribadi dan dikumpulkan langsung oleh peneliti. Salah satu tantangan utama yang ditemukan dalam penelitian tersebut adalah tingginya waktu komputasi yang diperlukan selama proses pelatihan. Hal ini disebabkan oleh kompleksitas arsitektur model yang digunakan, yang memerlukan perangkat keras dengan spesifikasi tinggi untuk menjalankan proses training secara efisien [10].

Berdasarkan permasalahan yang telah dijelaskan di atas, pada penelitian ini diusulkan penerapan CNN untuk klasifikasi buah secara otomatis. Penelitian ini bertujuan untuk mengklasifikasikan berbagai jenis buah dengan waktu komputasi yang lebih cepat, serta menghasilkan tingkat akurasi yang tinggi. Salah satu perbedaan utama antara penelitian ini dengan penelitian sebelumnya adalah penggunaan arsitektur model yang dikembangkan sendiri. Dengan menggunakan arsitektur model yang lebih ringan dan efisien, diharapkan dapat memperkecil waktu komputasi dan meningkatkan akurasi pengklasifikasian buah. Dengan demikian, penelitian ini bertujuan untuk mengembangkan model yang dapat digunakan secara praktis dalam industri pertanian dan distribusi pangan, serta memberikan solusi untuk mengatasi kendala-kendala yang ada pada proses pemilihan buah secara manual.

## **2. METODE**

Secara umum pada penelitian ini terdapat beberapa tahap penelitian yaitu, persiapan data, pengembangan model, pelatihan, serta evaluasi model yang digunakan.

### **2.1 Pengumpulan dan Persiapan Dataset**

Dataset yang digunakan dalam penelitian ini terdiri dari 22.495 gambar buah yang dikelompokkan dalam 33 kategori buah berbeda. Setiap kategori berisi gambar buah yang memiliki variasi dalam kondisi pencahayaan, sudut pandang, dan latar belakang. Dataset ini dibagi menjadi dua set: set pelatihan yang berjumlah 16.854 gambar (sekitar 75% dari total dataset) dan set pengujian sebanyak

### **2.2 Preprocessing Data**

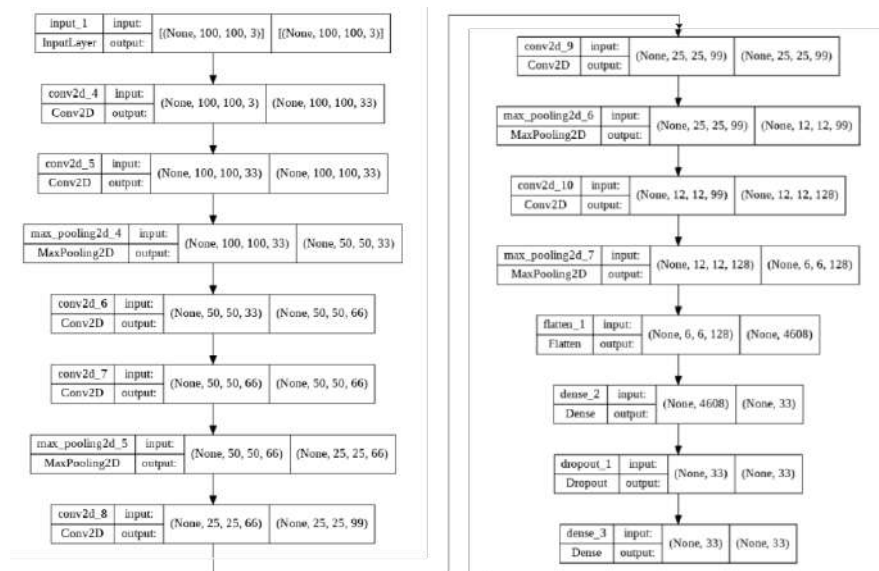
Sebelum digunakan untuk pelatihan data gambar akan melalui beberapa tahapan preprocessing guna memastikan kualitas yang baik dan meningkatkan efisiensi pelatihan model. Langkah pertama adalah rescaling, di mana semua gambar diubah skalanya menjadi rentang  $[0, 1]$  agar lebih memudahkan proses pelatihan. Selanjutnya, dilakukan augmentasi gambar untuk memperkaya dataset dan mengurangi risiko overfitting. Augmentasi ini melibatkan beberapa teknik, seperti rotasi, pemotongan, pencerminan, dan perubahan skala gambar, yang bertujuan untuk meningkatkan keragaman data latih dan membuat model lebih generalis.

### **2.2 Pembangunan Model CNN**

Model Convolutional Neural Network (CNN) yang dibangun dalam penelitian ini dirancang untuk mengekstraksi fitur secara bertahap dari gambar buah yang berukuran  $100 \times 100$  piksel dengan tiga saluran warna (RGB). Proses dimulai dengan lapisan input yang menerima gambar tersebut, diikuti oleh beberapa lapisan konvolusi (Conv2D) dan pooling (MaxPooling2D) untuk mengurangi dimensi dan mengekstraksi fitur penting. Pada lapisan pertama, gambar input diproses menggunakan lapisan Conv2D dengan 33 filter dan ukuran kernel  $3 \times 3$ . Padding yang digunakan adalah 'same' untuk memastikan ukuran gambar tetap konsisten setelah konvolusi. Fungsi aktivasi yang diterapkan adalah ELU (Exponential Linear Unit), yang dapat membantu mempercepat proses pelatihan dengan mengatasi masalah vanishing gradient. Setelah proses konvolusi pertama, lapisan MaxPooling2D dengan ukuran pool  $2 \times 2$  diterapkan untuk mereduksi dimensi gambar sekaligus mempertahankan fitur utama yang terdeteksi oleh filter konvolusi. Selanjutnya, pada lapisan kedua, jumlah filter ditingkatkan menjadi 66 filter dengan ukuran kernel yang sama, yaitu  $3 \times 3$ , dan fungsi aktivasi ELU. Lapisan ini juga diikuti oleh MaxPooling2D untuk lebih mengurangi dimensi citra yang telah diproses. Peningkatan jumlah filter pada lapisan ini memungkinkan model untuk mengekstraksi fitur yang lebih kompleks dan lebih detail dari citra.

Pada lapisan ketiga, jumlah filter kembali ditingkatkan menjadi 99 filter, dengan ukuran kernel yang tetap  $3 \times 3$  dan fungsi aktivasi ELU. Setelah dua lapisan konvolusi, lapisan MaxPooling2D kembali diterapkan untuk mengurangi ukuran spasial dari fitur yang dihasilkan dan mengurangi komputasi yang

diperlukan untuk pemrosesan lebih lanjut. Pada lapisan keempat, jumlah filter ditingkatkan menjadi 128 filter, masih dengan ukuran kernel 3x3 dan fungsi aktivasi ELU, serta diikuti oleh lapisan MaxPooling2D. Dengan lapisan-lapisan konvolusi dan pooling berturut-turut, model ini berhasil mengekstraksi fitur yang semakin kompleks dan mendalam dari gambar. Setelah melewati beberapa lapisan konvolusi dan pooling, fitur-fitur yang diekstraksi kemudian di flatten untuk mengubahnya menjadi vektor satu dimensi yang dapat diterima oleh lapisan fully connected (Dense). Lapisan Dense pertama terdiri dari 33 neuron dengan fungsi aktivasi ELU, diikuti oleh lapisan dropout dengan tingkat 0,2 untuk mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model.



Gambar 1. Rancangan Arsitektur Model

## 2.4 Pelatihan Model

Model CNN yang telah dibangun kemudian dilatih menggunakan dataset training set. Pelatihan model dilakukan selama beberapa epoch, dengan mengoptimalkan fungsi kerugian categorical crossentropy yang digunakan untuk masalah klasifikasi multikelas. Fungsi optimasi yang digunakan adalah Adam, yang dikenal efektif dalam mempercepat konvergensi dan mengurangi kemungkinan overfitting. Selain itu, penggunaan dropout sebesar 0,2 diterapkan di lapisan-lapisan dense untuk mencegah overfitting.

## 2.5 Evaluasi Model

Setelah proses pelatihan selesai, model dievaluasi menggunakan test set yang tidak digunakan selama pelatihan atau validasi. Model diuji untuk mengukur accuracy dan loss pada data yang belum pernah dilihat oleh model. Selain itu, evaluasi dilakukan dengan menggunakan classification report, yang mencakup metrik-metrik seperti precision, recall, dan F1-score untuk masing-masing kelas buah yang terklasifikasi

## 3. HASIL DAN PEMBAHASAN

Model Convolutional Neural Networks (CNN) yang dikembangkan dalam penelitian ini menunjukkan kinerja yang sangat baik dalam mengklasifikasikan berbagai jenis buah berdasarkan citra digital. Setelah dilakukan pelatihan dengan menggunakan dataset yang telah dipersiapkan, model mencapai akurasi pelatihan yang sangat tinggi, lebih dari 96% pada data latih. Akurasi pada data validasi juga menunjukkan performa yang stabil, dengan nilai validasi akurasi antara 96% hingga 100%. Hal ini

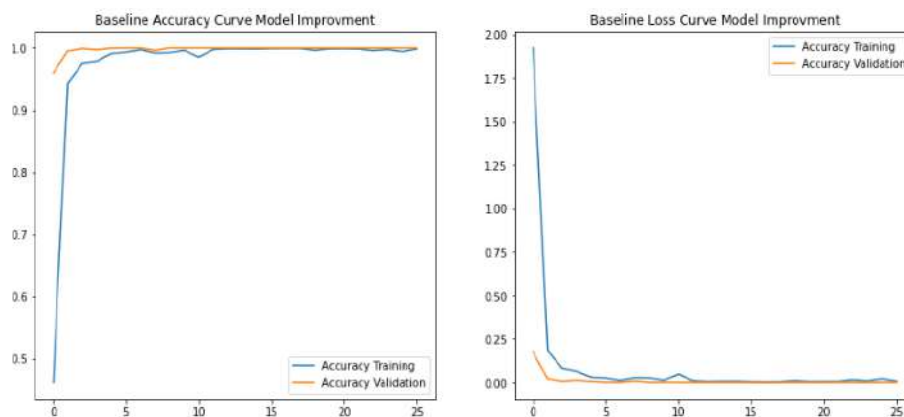
menunjukkan bahwa model dapat menggeneralisasi dengan baik, dan tidak terjadi overfitting meskipun data yang digunakan sangat bervariasi.

```
project_improv = model_improv.fit(  
    training_data,  
    epochs=100,  
    verbose=1,  
    validation_data=validation_data,  
    callbacks=callbacks  
)  
)
```

CPU times: user 3 µs, sys: 0 ns, total: 3 µs  
Wall time: 6.88 µs  
Epoch 1/100  
211/211 [=====] - 31s 142ms/step - loss: 1.5246 - accuracy: 0.4615 - val\_loss: 0.1769 - val\_accuracy: 0.9595  
Epoch 2/100  
211/211 [=====] - 29s 137ms/step - loss: 0.1845 - accuracy: 0.9430 - val\_loss: 0.8190 - val\_accuracy: 0.9953  
Epoch 3/100  
211/211 [=====] - 29s 137ms/step - loss: 0.8814 - accuracy: 0.9751 - val\_loss: 0.8059 - val\_accuracy: 0.9991  
Epoch 4/100  
211/211 [=====] - 35s 166ms/step - loss: 0.8631 - accuracy: 0.9785 - val\_loss: 0.8112 - val\_accuracy: 0.9973  
Epoch 5/100  
211/211 [=====] - 29s 138ms/step - loss: 0.8291 - accuracy: 0.9918 - val\_loss: 0.8047 - val\_accuracy: 0.9997  
Epoch 6/100  
211/211 [=====] - 30s 141ms/step - loss: 0.8250 - accuracy: 0.9932 - val\_loss: 4.7073e-04 - val\_accuracy: 1.0000  
Epoch 7/100  
211/211 [=====] - 38s 143ms/step - loss: 0.8101 - accuracy: 0.9975 - val\_loss: 3.7327e-04 - val\_accuracy: 1.0000  
Epoch 8/100  
211/211 [=====] - 29s 137ms/step - loss: 0.8267 - accuracy: 0.9918 - val\_loss: 0.8073 - val\_accuracy: 0.9965  
Epoch 9/100  
211/211 [=====] - 29s 139ms/step - loss: 0.8251 - accuracy: 0.9924 - val\_loss: 8.9438e-05 - val\_accuracy: 1.0000  
Epoch 10/100  
211/211 [=====] - 29s 136ms/step - loss: 0.8116 - accuracy: 0.9965 - val\_loss: 4.1071e-04 - val\_accuracy: 1.0000  
Epoch 11/100  
211/211 [=====] - 29s 137ms/step - loss: 0.8470 - accuracy: 0.9858 - val\_loss: 1.8133e-04 - val\_accuracy: 1.0000  
Epoch 12/100  
...  
Epoch 25/100  
211/211 [=====] - 29s 137ms/step - loss: 0.8211 - accuracy: 0.9943 - val\_loss: 1.1462e-05 - val\_accuracy: 1.0000  
Epoch 10/100  
211/211 [=====] - 29s 137ms/step - loss: 0.8057 - accuracy: 0.9985 - val\_loss: 5.9276e-05 - val\_accuracy: 1.0000  
Output is truncated. View as a [scrollable element](#) or open in a [text editor](#). Adjust cell output [settings](#).

Gambar 2. Iterasi Epoch

Selama pelatihan peneliti juga memvisualisasikan grafik iterasi epoch untuk mengamati proses konvergensi model, yang menunjukkan bagaimana akurasi dan loss berubah seiring dengan bertambahnya epoch. Gambar 1 menunjukkan iterasi epoch yang menggambarkan proses pelatihan model dari awal hingga akhir, serta perubahan akurasi dan loss selama iterasi. Grafik ini memberikan gambaran tentang bagaimana model belajar dan berkembang seiring dengan meningkatnya jumlah epoch.



Gambar 3. Baseline Accuracy and Loss Curves

Grafik baseline accuracy curve menunjukkan peningkatan signifikan dalam akurasi pelatihan dan validasi, mencerminkan bahwa model belajar secara efektif dan mencapai performa yang sangat baik pada data uji. Sebaliknya, baseline loss curve memperlihatkan penurunan yang konsisten dalam nilai loss selama pelatihan, yang mengindikasikan bahwa model secara bertahap meminimalkan kesalahan dan meningkatkan kemampuannya dalam mengklasifikasikan gambar buah.

Selain itu model berhasil mengklasifikasikan hampir semua kelas buah dengan tingkat presisi, recall, dan f1-score yang sangat tinggi, masing-masing mendekati nilai 1.0, yang mengindikasikan bahwa model tidak hanya akurat dalam mengklasifikasikan buah tetapi juga mampu menghindari kesalahan klasifikasi yang signifikan.

Tabel 1. Hasil Classification Report pada Data Uji

| Kelas Buah         | Precision | Recall | F1-Score | Support |
|--------------------|-----------|--------|----------|---------|
| Apple Braeburn     | 1.00      | 1.00   | 1.00     | 99      |
| Apple Granny Smith | 1.00      | 1.00   | 1.00     | 99      |
| Apricot            | 1.00      | 1.00   | 1.00     | 99      |
| Avocado            | 1.00      | 1.00   | 1.00     | 89      |
| Banana             | 1.00      | 1.00   | 1.00     | 93      |
| Blueberry          | 1.00      | 1.00   | 1.00     | 98      |
| Cactus fruit       | 1.00      | 1.00   | 1.00     | 99      |
| Cantaloupe         | 1.00      | 1.00   | 1.00     | 99      |
| Cherry             | 1.00      | 1.00   | 1.00     | 98      |
| Clementine         | 1.00      | 1.00   | 1.00     | 90      |
| Corn               | 1.00      | 1.00   | 1.00     | 79      |
| Cucumber Ripe      | 1.00      | 1.00   | 1.00     | 97      |
| Grape Blue         | 1.00      | 1.00   | 1.00     | 94      |
| Kiwi               | 1.00      | 1.00   | 1.00     | 99      |
| Lemon              | 1.00      | 1.00   | 1.00     | 98      |
| Limes              | 1.00      | 1.00   | 1.00     | 98      |
| Mango              | 1.00      | 1.00   | 1.00     | 88      |
| Onion White        | 1.00      | 1.00   | 1.00     | 96      |
| Orange             | 1.00      | 1.00   | 1.00     | 99      |
| Papaya             | 1.00      | 1.00   | 1.00     | 98      |
| Passion Fruit      | 1.00      | 1.00   | 1.00     | 98      |
| Peach              | 1.00      | 1.00   | 1.00     | 99      |
| Pear               | 1.00      | 1.00   | 1.00     | 140     |
| Accuracy           |           |        | 1.00     | 3383    |
| macro avg          | 1.00      | 1.00   | 1.00     | 3383    |
| weighted avg       | 1.00      | 1.00   | 1.00     | 3383    |

Tabel ini menunjukkan hasil evaluasi untuk beberapa kelas buah, dimana nilai presisi, recall, dan f1-score hampir semuanya mencapai 1.00, mengindikasikan bahwa model berhasil mengklasifikasikan jenis buah dengan sangat akurat.



Gambar 4. Hasil engine mengklasifikasi jenis buah

#### 4. KESIMPULAN

Penelitian ini telah berhasil menerapkan Convolutional Neural Networks (CNN) untuk mengklasifikasikan jenis buah berdasarkan citra digital. Berdasarkan hasil eksperimen model CNN yang

dikembangkan menunjukkan performa yang sangat baik dengan tingkat akurasi yang sangat tinggi (di atas 96%) pada data pelatihan dan validasi, serta presisi, recall, dan f1-score yang mendekati nilai 1.0 untuk sebagian besar kelas buah.

Keberhasilan model ini menegaskan bahwa penggunaan CNN dalam klasifikasi citra buah sangat efektif bahkan dengan variasi dalam bentuk, ukuran, warna, dan kondisi pencahayaan buah. Dengan demikian, metode ini berpotensi untuk diimplementasikan dalam berbagai aplikasi praktis di sektor pertanian, distribusi makanan, dan pengolahan citra seperti sistem otomatis untuk identifikasi dan pemeriksaan kualitas buah.

Namun, meskipun model menunjukkan hasil yang sangat baik, penelitian ini juga menyarankan beberapa area untuk pengembangan lebih lanjut seperti peningkatan variasi dataset untuk mencakup lebih banyak kondisi pencahayaan dan perspektif gambar serta eksperimen dengan arsitektur CNN yang lebih kompleks atau penggabungan teknik augmentasi data untuk meningkatkan generalisasi model.

## REFERENSI

- [1] L. Muda Harahap, T. Gloria Pakpahan, R. Aulia Wijaya, and A. Zacky Nasution, "Publikasi Ilmu Tanaman dan Agribisnis (BOTANI) Dampak Transformasi Digital pada Agribisnis: Tantangan dan Peluang bagi Petani di Indonesia," *Botani*, vol. 1, no. 2, pp. 99–108, 2024, [Online]. Available: <https://doi.org/10.62951/botani.v1i2.55>
- [2] Masliani, D. I. H., Mahrita, S., Sari, M., & Lestari, Y. M. (2024). Pertanian era modern: Dinamika pertanian dan solusi inovatif untuk petani. PT Media Penerbit Indonesia.
- [3] M. I. Dinata, N. Sulistianingsih, and S. A. A. Yusuf, "Implementasi Deep Learning Dalam Klasifikasi Citra Gambar Dengan Menggunakan Metode CNN," *J. Inf. Technol. Syst.*, pp. 14–19, 2023.
- [4] M. S. Ummah, *Supply Chain Management*, vol. 11, no. 1. 2019. [Online]. Available: [http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484\\_SISTEM\\_PEMBETUNGAN\\_TERPUS\\_AT\\_STRATEGI\\_MELESTARI](http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUS_AT_STRATEGI_MELESTARI)
- [5] A. ANHAR and R. A. PUTRA, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 2, p. 466, 2023, doi: 10.26760/elkomika.v11i2.466.
- [6] S. R. Suartika E. P, I Wayan, Wijaya Arya Yudhi, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, p. 76, 2016, [Online]. Available: <http://repository.its.ac.id/48842/>
- [7] T. Dwi Antoko, M. Azhar Ridani, and A. Eko Minarno, "Klasifikasi Buah Zaitun Menggunakan Convolution Neural Network," *Komputika J. Sist. Komput.*, vol. 10, no. 2, pp. 119–126, 2021, doi: 10.34010/komputika.v10i2.4475.
- [8] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network \_ Ilahiyah \_ JUSTINDO (Jurnal Sistem dan Teknologi Informasi Indonesia)," *JUSTINDO(Jurnal Sist. Teknol. Inf. Indones.*, vol. 3, no. 2, pp. 49–56, 2018.
- [9] M. O. Al-Shawwa and S. S. Abu-Naser, "Classification of Apple Fruits by Deep Learning," *Int. J. Acad. Eng. Res.*, vol. 3, no. 12, pp. 1–7, 2019, [Online]. Available: [www.ijeais.org/ijaer](http://www.ijeais.org/ijaer)
- [10] J. M. Ponce, A. Aquino, and J. M. Andújar, "Olive-fruit variety classification by means of image processing and convolutional neural networks," *IEEE Access*, vol. 7, p. 147629, 2019, doi: 10.1109/ACCESS.2019.2947160.