



Image-Based Vegetable Type Classification Using Convolutional Neural Network with Nutritional Content Information Provision

Klasifikasi Jenis Sayuran Berbasis Citra Menggunakan *Convolutional Neural Network* dengan Penyediaan Informasi Kandungan Nutrisi

Intan Idaman Halawa^{1*}, Choirul Basir²

^{1,2}Program Studi Matematika, Universitas Pamulang, Indonesia

E-Mail: ¹intanhalawa2@gmail.com, ²dosen02278@unpam.ac.id

Received Aug 19th 2025; Revised Mar 13th 2026; Accepted Apr 18th 2026; Available Online Apr 26th 2026

Corresponding Author: Intan Idaman Halawa

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Many vegetable types share similar shapes, colors, and sizes, making manual distinction difficult and error-prone. Additionally, limited public knowledge about vegetable nutrition suitable for personal health conditions presents further challenges. This research proposes an image-based vegetable classification model using a Convolutional Neural Network (CNN) deep learning method with TensorFlow, integrated with automatic provision of nutritional information. The dataset includes 15 common vegetables broccoli, capsicum, beans, cauliflower, potato, cabbage, bottle gourd, bitter melon, radish, cucumber, papaya, eggplant, tomato, pumpkin, and carrot, with a total of 21,000 images divided into training set (15,000 images), validation set (3,000 images), and test set (3,000 images). A sequential CNN model with 8 layers was trained with various input parameters, epochs, and evaluation metrics. The best model achieved training accuracy of 92.8%, validation accuracy of 95.83%, and testing accuracy of 95.67%. Evaluation using a confusion matrix yielded 96% overall accuracy, with the highest precision of 99%, recall of 100%, and F1-score of 100%. The proposed model has potential applications in nutrition tracking, food quality control, and food product development.

Keywords: Classification, Convolutional Neural Network, Deep Learning, Tensorflow, Vegetable

Abstrak

Banyak jenis sayuran memiliki tampilan yang mirip dalam hal bentuk, warna, dan ukuran, sehingga sulit dibedakan secara manual karena membutuhkan waktu lama dan rentan terhadap kesalahan. Selain itu, rendahnya pengetahuan masyarakat tentang nutrisi sayuran yang sesuai dengan kondisi kesehatan pribadi menjadi tantangan tersendiri. Penelitian ini merancang model klasifikasi sayuran berbasis citra menggunakan *deep learning* dengan metode *Convolutional Neural Network* (CNN) berbasis TensorFlow yang diintegrasikan dengan penyediaan informasi kandungan nutrisi secara otomatis. *Dataset* mencakup 15 jenis sayuran umum: brokoli, *capsicum*, kacang, kembang kol, kentang, kubis, labu botol, labu pahit, lobak, mentimun, pepaya, terong, tomat, waluh, dan wortel, dengan total 21.000 citra yang dibagi menjadi data latih (*training set* 15.000 citra), data validasi (*validation set* 3.000 citra), dan data uji (*test set* 3.000 citra). Model CNN dengan arsitektur *sequential* 8 lapisan dilatih dengan variasi parameter masukan, *epoch*, dan metrik evaluasi. Model terbaik menunjukkan *training accuracy* 92,8%, *validation accuracy* 95,83%, dan *testing accuracy* 95,67%. Evaluasi menggunakan *confusion matrix* menghasilkan akurasi keseluruhan 96%, presisi tertinggi 99%, *recall* tertinggi 100%, dan *F1-score* tertinggi 100%. Model yang diusulkan berpotensi dimanfaatkan untuk pelacakan gizi, kontrol kualitas makanan, dan pengembangan produk pangan.

Kata Kunci: Convolutional Neural Network, Deep Learning, Klasifikasi, Sayuran, Tensorflow

1. PENDAHULUAN

Sayuran merupakan makanan yang sering dikonsumsi masyarakat Indonesia karena mengandung nutrisi yang baik bagi kesehatan tubuh. Sayuran merupakan sumber vitamin, mineral, air, protein, lemak, serat, dan asam amino yang terjangkau dan mudah diperoleh [1]. Sayuran juga merupakan makanan nabati dengan kadar air tinggi yang dapat dikonsumsi segar atau setelah sedikit pengolahan [2]. Konsumsi sayuran yang cukup dapat membantu proses detoksifikasi untuk membersihkan racun dalam tubuh, mencegah risiko kelahiran bayi cacat, meningkatkan kesehatan kulit, dan memperkuat struktur tulang [3].

Data *World Health Organization* (WHO) pada tahun 2016 menunjukkan terdapat 2,8 juta orang yang meninggal akibat masalah kelebihan berat badan dan obesitas, sedangkan menurut Kementerian Kesehatan Indonesia, prevalensi kelebihan berat badan dan obesitas di Indonesia pada tahun 2018 masing-masing mencapai 13,6% dan 21,8% [4]. Sayuran berwarna hijau, khususnya jenis silangan seperti brokoli, terbukti efektif dalam mengurangi lemak di area perut. Sayuran silangan mengandung glukosinolat yang bermanfaat bagi kesehatan [5].

Perkembangan teknologi *computer vision* saat ini membawa berbagai pengaruh yang signifikan dalam berbagai aspek kehidupan. Aplikasi *computer vision* telah merambah ke berbagai sektor, termasuk kedokteran, kemiliteran, industri, perdagangan, pertanian, dan lainnya [6], [7]. *Computer vision* adalah cabang ilmu yang memberikan kemampuan penglihatan pada komputer atau mesin, serupa dengan kemampuan penglihatan manusia. Klasifikasi citra menjadi fokus utama dalam menyelesaikan permasalahan *computer vision*, dengan tujuan mengkategorikan citra ke dalam kategori tertentu [6], [7], [8].

Berbagai metode *machine learning* telah diterapkan untuk klasifikasi citra sayuran, mulai dari metode konvensional seperti *Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN), dan *Artificial Neural Network* (ANN) tradisional, hingga metode *deep learning* yang lebih modern. Metode konvensional seperti SVM dan KNN umumnya memerlukan proses ekstraksi fitur secara manual (*handcrafted features*) sebelum klasifikasi, yang membutuhkan keahlian domain dan bersifat sensitif terhadap variasi citra [24]. ANN konvensional memiliki keterbatasan dalam menangkap fitur spasial dari citra secara hierarkis [25]. *Convolutional Neural Network* (CNN) hadir sebagai solusi yang lebih unggul karena mampu melakukan ekstraksi fitur secara otomatis langsung dari piksel citra melalui mekanisme konvolusi bertingkat [9], [10]. CNN telah terbukti efektif dalam pengenalan gambar, termasuk klasifikasi citra dan deteksi objek, serta dapat menangani variasi bentuk, ukuran, dan kondisi gambar dalam proses identifikasi sayuran berbasis citra [10], [11]. Hasan *et al.* (2024) menunjukkan bahwa CNN mampu mencapai akurasi 98% pada klasifikasi citra MNIST menggunakan arsitektur berlapis, yang membuktikan keunggulan CNN dibandingkan dengan metode konvensional untuk tugas klasifikasi citra berdimensi tinggi [25].


Penelitian terkini menunjukkan bahwa CNN dengan arsitektur MobileNetV2 mampu mengklasifikasikan 36 jenis buah dan sayuran dengan akurasi 97,31% [20], sementara pendekatan CNN *from scratch* dengan TensorFlow/Keras pada 15 kelas sayuran mencapai *testing accuracy* 93% [21]. Selain itu, arsitektur EfficientNet, GoogLeNet, dan ResNet telah terbukti mampu mengidentifikasi sayuran dalam kondisi lapangan dengan akurasi lebih dari 95,6% [22]. Studi perbandingan oleh Alshammari (2024) mengonfirmasi bahwa pendekatan berbasis *deep learning* secara konsisten menghasilkan kinerja yang lebih tinggi dibandingkan dengan metode *machine learning* konvensional seperti SVM dan KNN untuk tugas klasifikasi citra yang kompleks [24].

Menurut data FAOSTAT, terdapat lebih dari 200 jenis sayuran yang tersebar di berbagai negara [12]. Di Indonesia sendiri, lebih dari lima puluh jenis sayuran dapat ditemukan dengan mudah, seperti pare, daun kelor, *kale*, jantung pisang, bunga dan daun pepaya, jengkol, pakis, terong, bayam, kangkung, sawi, selada, kubis, wortel, kacang panjang, buncis, tomat, labu siam, labu kuning, labu air, bawang merah, bawang putih, dan lain sebagainya [1], [8].

Penelitian ini bertujuan merancang model CNN yang akurat dan efisien untuk mengklasifikasikan 15 jenis sayuran yang umum dikonsumsi di Indonesia berdasarkan citra digital, serta menyediakan informasi kandungan nutrisi secara otomatis melalui integrasi dengan basis data gizi yang telah disiapkan. Model yang diusulkan diharapkan dapat memberikan kontribusi dalam mendukung masyarakat untuk memilih sayuran yang tepat sesuai kondisi kesehatan mereka, serta meningkatkan kesadaran akan pentingnya konsumsi sayuran yang beragam untuk mendukung pola hidup sehat.

2. METODOLOGI PENELITIAN

Jenis penelitian ini adalah penelitian terapan (*applied research*) dengan elemen penelitian eksperimental (*experimental research*) yang bertujuan merancang model CNN yang efisien untuk klasifikasi sayuran berbasis citra [13]. Adapun tahapan penelitian dalam perancangan model klasifikasi dapat dilihat pada Gambar 1.



Gambar 1. Alur dan Tahapan Penelitian

2.1. Pengumpulan Data

Penelitian ini menggunakan data sekunder yang diperoleh dari Kaggle, berupa *dataset* sayuran yang terdiri atas 21.000 citra yang mencakup 15 jenis sayuran. *Dataset* tersebut dibagi secara acak (*random splitting*) dengan proporsi 70%/15%/15% menjadi data latih (*training set* 15.000 citra), data validasi (*validation set* 3.000 citra), dan data uji (*test set* 3.000 citra). Setiap jenis sayuran memiliki 200 citra pada data uji. *Dataset* terdiri atas 15 jenis sayuran, yaitu brokoli, cabai paprika (*capsicum*), kacang-kacangan, kembang kol, kentang, kubis, labu botol, pare (labu pahit), lobak, mentimun, pepaya, terong, tomat, labu kuning (waluh), dan wortel.

2.2. Data Preprocessing

Preprocessing data merupakan proses peningkatan kualitas citra sebelum tahap ekstraksi fitur. Proses ini terdiri atas empat tahap utama [14].

1. *Random Splitting* adalah teknik pembagian *dataset* secara acak yang diterapkan pada 21.000 gambar menjadi tiga sub-*dataset* dengan proporsi 70%/15%/15%, yang menghasilkan 15.000 gambar untuk data latih, 3.000 gambar untuk data validasi, dan 3.000 gambar untuk data uji. Teknik ini memastikan setiap data memiliki peluang yang sama untuk masuk ke dalam sub-*dataset* tertentu sehingga mengurangi bias dalam proses pembelajaran model.
2. *Cleaning* data bertujuan mengidentifikasi dan menghilangkan kesalahan, ketidakkonsistenan, serta data duplikat menggunakan fungsi *hash* yang membandingkan berkas berdasarkan waktu dan ukuran tanpa membuka berkas secara manual.
3. *Resizing* dan normalisasi gambar dilakukan untuk menyeragamkan dimensi gambar dan mengubah skala nilai piksel ke rentang 0–1 guna mempercepat konvergensi dan mencegah dominasi fitur berskala besar. Dalam penelitian ini digunakan normalisasi skala (*min-max scaling*) yang mentransformasi nilai piksel ke dalam rentang [0, 1].
4. Augmentasi data dilakukan melalui teknik pembalikan horizontal, penggeseran horizontal-vertikal, rotasi acak, transformasi *shear* dan *zoom*, serta pengisian area kosong untuk meningkatkan ukuran dan keragaman *dataset*, mengurangi *overfitting*, dan memperkuat ketahanan model terhadap gangguan.

2.3. Desain Model CNN

Desain arsitektur model CNN dalam penelitian ini melalui beberapa tahapan sistematis yang dimulai dengan pengimporan *library* yang diperlukan untuk membangun model. Selanjutnya, didefinisikan *sequential model* yang memungkinkan penambahan lapisan secara berurutan sesuai alur pemrosesan data [15]. Tahap ekstraksi fitur dilakukan melalui penyusunan *convolutional layers* yang berfungsi mendeteksi pola dan karakteristik penting dari citra sayuran.

Untuk mengurangi dimensi data dan meningkatkan efisiensi komputasi, diterapkan lapisan *pooling* yang melakukan *downsampling* dengan tetap mempertahankan informasi penting [16]. Data kemudian diubah dari format multidimensi menjadi format satu dimensi melalui lapisan *flatten* agar dapat diproses oleh lapisan *fully-connected*. *Dense layer* pertama digunakan untuk mempelajari hubungan kompleks antara fitur yang telah diekstrak, sementara *dense layer* akhir dengan *dropout* diterapkan untuk mencegah *overfitting* dan melakukan klasifikasi final terhadap 15 kelas sayuran. Rancangan arsitektur model CNN yang digunakan dapat dilihat pada Gambar 2.

```
# Membangun Model CNN
model = Sequential()
model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(224, 224, 3)))
model.add(MaxPooling2D((2, 2)))
model.add(Conv2D(64, (3, 3), activation='relu'))
model.add(MaxPooling2D((2, 2)))
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(len(classes), activation='softmax'))
```


Gambar 2. Rancangan Model CNN

2.4. Model Training

Dalam penelitian ini, terdapat tiga model CNN yang dirancang dan dilatih menggunakan data yang telah disiapkan. Model dibangun berdasarkan ukuran citra masukan, jumlah metrik, jumlah *epoch*, dan jumlah lapisan untuk mencapai hasil yang diharapkan.


1. Model Pertama memuat beberapa lapisan *convolution*, lapisan *pooling* dan menggunakan *dropout* setelah *max pooling layer*. Adapun *size input* citra [64, 64, 3] yang menunjukkan bahwa model CNN akan menerima citra dengan tinggi 64 piksel, lebar 64 piksel, dan memiliki tiga saluran warna yaitu merah, hijau, dan biru (RGB). Kemudian, metrik yang digunakan yaitu *accuracy* dengan 30 *epochs*.

Percobaan ini menghasilkan *training accuracy* 99,5%, *validation accuracy* 92%, *loss training* 1,7% dan *loss validation accuracy* sebesar 79,2%. Dapat dilihat bahwa performa model menurun pada data yang belum pernah dilihat sebelumnya (data validasi), yang menunjukkan adanya *overfitting*. Gambar 3 adalah *output training* model pertama.



Gambar 3. *Output Training Model Pertama*

- Model Kedua mengurangi jumlah *convolutional layer* dan *layer dense* untuk mengurangi kompleksitas model. Jumlah matriks *stride* pada lapisan *conv2d* dikurangi menjadi 16 dengan ukuran *kernel* 3×3, ukuran citra masukan [128, 128, 3], metrik akurasi dan presisi, serta 10 *epoch*. Diperoleh *training accuracy* 6,72%, *validation accuracy* 6,67%, dan *loss* 270,81%, yang menunjukkan bahwa model tidak melakukan prediksi dengan baik sehingga tidak diperlukan percobaan lanjutan. Gambar 4 adalah *output training* model kedua.



Gambar 4. *Output Training Model Kedua*

- Model Ketiga memiliki lapisan yang lebih sedikit dari model sebelumnya. Sebelumnya model ini telah dilakukan pemeriksaan ulang dan penambahan augmentasi pada dataset yang digunakan untuk mencegah *overfitting*. Pada model ini dilakukan dua kali percobaan dengan Ukuran *input* yang digunakan yaitu [224, 224, 3] dengan *kernel* 3 x 3, metrik *accuracy* dan *precision* dengan 10 *epochs* pada percobaan pertama. Diperoleh *training accuracy* 84,75%, *validation accuracy* 91,9%, *loss*

training 45,81% dan loss validation accuracy 28,9% dan testing accuracy 91,39%. Sementara, pada percobaan kedua jumlah *epoch* ditambah menjadi 20. Diperoleh *training accuracy* 92,8%, *validation accuracy* 95,83%, *loss training* 21,54%, *loss validation accuracy* 18,62%, dan *testing accuracy* 95,67%.

Tabel 1. Ouput Percobaan Pertama dan Kedua pada Model Ketiga

Percobaan Pertama	Percobaan Kedua
1/1 [=====] - 0s 69ms/ste	1/1 [=====] - 0s 49ms/step
Predicted class: Kubis	Predicted class: Kubis
	
Actual class: Kubis Actual image: 1138.jpg Kubis 77.86% Kembang Kol 10.61% Waluh 9.57% Brokoli 1.24% Tomat 0.46%	Actual class: Kubis Actual image: 1043.jpg Kubis 92.90% Kembang Kol 6.36% Waluh 0.64% Brokoli 0.10% Tomat 0.00%

Dari Tabel 1 terlihat bahwa persentase akurasi percobaan pertama dan kedua mengalami peningkatan seiring bertambahnya jumlah *epoch*. Hal ini menunjukkan bahwa model mengekstrak fitur relevan dari data latih dan membuat prediksi yang lebih baik dari waktu ke waktu.

2.5. Metrik Evaluasi

Hasil klasifikasi dianalisis menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* yang dihitung berdasarkan nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) dari *confusion matrix* [17], [18]. *Confusion matrix* merupakan tabel yang menampilkan hasil prediksi model dan berfungsi untuk mengevaluasi kinerja algoritma klasifikasi [18], [23]. Baris pada *confusion matrix* merepresentasikan kelas aktual (*actual class*), sedangkan kolom merepresentasikan kelas hasil prediksi (*predicted class*). Susunan *confusion matrix* yang digunakan mengacu pada Han, Kamber, & Pei (2012) sebagaimana ditunjukkan pada Tabel 2 [19].

Tabel 2. Confusion Matrix

		Predicted Class	
		True	False
Actual Class	Positive	True Positive (TP)	False Positive (FP)
	Negative	True Negative (TN)	False Negative (FN)

Keterangan:

- TP : Sayuran yang benar diidentifikasi sesuai kelasnya
- TN : Sayuran yang benar diidentifikasi sebagai bukan bagian dari kelas
- FP : Sayuran yang salah diidentifikasi sebagai bagian dari kelas
- FN : Sayuran yang salah diidentifikasi sebagai bukan bagian dari kelas

Selanjutnya, keempat metrik evaluasi yang digunakan didefinisikan sebagai berikut [10], [18], [19]. Akurasi merupakan persentase prediksi yang benar dari keseluruhan prediksi yang dihasilkan oleh model.

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

Presisi adalah metrik yang mengukur seberapa tepat prediksi positif yang dihasilkan model, yaitu rasio antara prediksi positif yang benar terhadap seluruh prediksi positif.

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

Recall merupakan metrik sensitivitas yang mencerminkan seberapa banyak kasus positif yang sebenarnya berhasil diprediksi dengan benar sebagai positif oleh model.


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

F1-score adalah metrik yang menggabungkan presisi dan *recall* dalam satu ukuran tunggal guna mengevaluasi kinerja model secara seimbang. Adapun formula untuk menghitung keempat metrik evaluasi tersebut adalah sebagai berikut

$$F - 1 \text{ Score} = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Berdasarkan *output* dari *training* ketiga model sebelumnya, model terbaik yaitu model ketiga yang menggunakan arsitektur *sequential* dengan delapan *layer* yang disusun berurutan.



Gambar 5. Grafik Akurasi *Training* dan Validasi

Grafik akurasi data latih dan data validasi pada Gambar 5 menunjukkan bahwa kedua kurva meningkat secara stabil seiring bertambahnya jumlah *epoch* tanpa terjadi divergensi yang signifikan. Kurva *training* dan validasi bergerak berdekatan sepanjang proses pelatihan, yang mengindikasikan bahwa model tidak mengalami *overfitting* dan mampu mengekstrak fitur visual dari citra sayuran secara bertahap dan efektif. Pada *epoch* ke-20, model mencapai *training accuracy* 92,8% dan *validation accuracy* 95,83%, dengan selisih yang kecil (sekitar 3%) sebagai bukti bahwa kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya terjaga dengan baik.

3.1. Hasil Pengujian Model

Pengujian model dilakukan menggunakan dataset uji setelah proses pelatihan selesai. Sebagai ilustrasi, hasil pengujian pada citra tomat menunjukkan bahwa model CNN mampu mengklasifikasikan citra dengan akurasi 100% untuk kelas tomat, sementara probabilitas untuk kelas sayuran lainnya (lobak, kembang kol, wortel, dan kacang) bernilai 0,00%. Hasil ini mengindikasikan bahwa model telah mampu membedakan karakteristik visual tomat dari jenis sayuran lainnya secara akurat.

Setelah klasifikasi berhasil dilakukan, model secara otomatis menampilkan informasi kandungan nutrisi yang bersumber dari basis data terstruktur, bukan diestimasi dari piksel citra. Kandungan nutrisi tomat per 100 gram yang ditampilkan meliputi vitamin A (450 IU), vitamin B6 (0,06 mg), vitamin C (40,0 mg), vitamin E (0,0 mg), serat (1.200 mg), karbohidrat (3.920 mg), lemak (200,0 mg), protein (880 mg), gula (2.630 mg), kalium (237 mg), magnesium (0,0 mg), natrium (5,0 mg), kalsium (7 mg), zat besi (0,9 mg), fosfor (27,0 mg), dan total kalori 20 kkal. Berdasarkan profil nutrisi tersebut, model menampilkan manfaat kesehatan tomat berupa kemampuannya dalam melindungi sel tubuh dari kerusakan oksidatif, yang relevan dengan kandungan vitamin C sebagai antioksidan dan kalium yang berperan dalam menjaga kesehatan jantung serta regulasi tekanan darah. Hasil pengujian secara lengkap disajikan pada Tabel 3.

Tabel 3. Hasil Klasifikasi dan Informasi Nutrisi Tomat

Hasil Pengujian		Nutrisi dan Manfaat						
1/1 [=====] - 0s 42ms/step		Vegetable Content for Tomat						
Predicted class: Tomat		Nama Sayur	Vitamin A	Vitamin B6	Vitamin C	Vitamin E		
		9 Tomat	450	0.06	40.0	0.0		
		Serat	Karbohidrat	Lemak	Protein	Gula	Kalium	Magnesium
		1200	3920	200.0	880	2630	237	0.0
		Natrium/Sodium	Calsium	Zat Besi	Fosfor	Kalori (kcl)		
		5.0	7	0.9	27.0	20		
		Manfaat						
		Melindungi sel-sel tubuh agar tidak rusak						
Actual class: Tomat								
Actual image: 1129.jpg								
Tomat 100.00%								
Lobak 0.00%								
Kembang Kol 0.00%								
Wortel 0.00%								
Kacang 0.00%								

3.2. Analisis Metrik Evaluasi

Untuk memperoleh nilai metrik evaluasi, *confusion matrix* ditampilkan dari Python sebagaimana terlihat pada Gambar 6. Baris mewakili label kelas aktual, sedangkan kolom mewakili label kelas prediksi. Bagian diagonal merupakan nilai TP, yakni hasil prediksi model yang sesuai dengan kelas sebenarnya (*actual class*), sedangkan angka di luar diagonal merupakan nilai kesalahan prediksi, baik FP maupun FN.

[	189	0	1	1	0	0	0	3	1	0	0	0	0	5	0]
[	0	197	2	0	0	0	0	0	0	0	0	0	1	0	0]
[	0	0	190	0	0	0	0	7	2	0	0	1	0	0	0]
[	2	0	0	188	0	1	0	2	2	1	0	0	0	4	0]
[	0	0	0	0	200	0	0	0	0	0	0	0	0	0	0]
[	6	0	0	1	0	177	0	10	1	0	0	0	0	5	0]
[	0	0	0	0	0	0	197	0	0	0	3	0	0	0	0]
[	0	0	0	1	0	0	0	198	1	0	0	0	0	0	0]
[	0	0	0	0	1	0	0	0	199	0	0	0	0	0	0]
[	0	0	3	3	0	0	1	2	0	190	0	0	1	0	0]
[	0	2	0	0	0	0	0	3	0	0	192	3	0	0	0]
[	0	1	4	5	0	2	6	1	0	0	2	178	0	1	0]
[	1	2	2	2	2	2	0	0	4	0	0	0	181	2	2]
[	2	0	0	1	0	0	0	2	0	1	0	0	0	194	0]
[	0	0	0	0	0	0	0	0	0	0	0	0	0	0	200]]

Gambar 6. Confusion Matriks dari 15 Sayuran

Secara lengkap tabel *confusion matrix* yang memuat TP, FP, FN dan TN dari 15 kelas diuraikan pada Tabel 4.

Tabel 4. Nilai TP, FP, FN dan TN pada *Confusion Matrix*

No	Label	Jumlah	TP	FP	FN	TN
1	Brokoli	200	189	11	11	2789
2	Capsicum	200	197	3	5	2795
3	Kacang	200	190	10	12	2788
4	Kembang Kol	200	188	12	14	2786
5	Kentang	200	200	0	3	2797
6	Kubis	200	177	23	5	2795
7	Labu Botol	200	197	3	7	2793
8	Labu Pahit	200	198	2	30	2770
9	Lobak	200	199	1	11	2789
10	Mentimun	200	190	10	2	2798
11	Pepaya	200	192	8	5	2795
12	Terong	200	178	22	4	2796
13	Tomat	200	181	19	2	2798
14	Waluh	200	194	6	17	2783
15	Wortel	200	200	0	2	2798
Total		3000	2870	130	130	41870

Dari Tabel 4, terlihat bahwa secara keseluruhan model memiliki kinerja yang baik, di mana jumlah citra yang diklasifikasi dengan tepat (TP = 2.870) jauh lebih besar dibandingkan jumlah kesalahan klasifikasi (FN = 130). Nilai-nilai yang diperoleh dari *confusion matrix* tersebut selanjutnya digunakan untuk menghitung metrik akurasi, presisi, *recall*, dan *F1-score* pada setiap kelas sayuran, baik secara manual menggunakan persamaan (1), (2), (3), (4) maupun melalui *output* Python. Nilai metrik pada masing-masing kelas sayuran ditampilkan pada Gambar 7.

	precision	recall	f1-score	support
0	0.94	0.94	0.94	200
1	0.98	0.98	0.98	200
2	0.94	0.95	0.95	200
3	0.93	0.94	0.94	200
4	0.99	1.00	0.99	200
5	0.97	0.89	0.93	200
6	0.97	0.98	0.98	200
7	0.87	0.99	0.93	200
8	0.95	0.99	0.97	200
9	0.99	0.95	0.97	200
10	0.97	0.96	0.97	200
11	0.98	0.89	0.93	200
12	0.99	0.91	0.95	200
13	0.92	0.97	0.94	200
14	0.99	1.00	1.00	200
accuracy			0.96	3000
macro avg	0.96	0.96	0.96	3000
weighted avg	0.96	0.96	0.96	3000

Gambar 7. Nilai Metrik Masing-Masing Kelas Sayuran

Berdasarkan *output* Python tersebut, kelas kentang (indeks 4) dan wortel (indeks 14) mencapai *recall* sempurna sebesar 1,00 dengan *F1-score* masing-masing 0,99 dan 1,00, yang menunjukkan bahwa kedua kelas ini dikenali dengan sangat baik oleh model. Sebaliknya, kelas labu pahit (indeks 7) memiliki *recall* terendah sebesar 0,87 konsisten dengan nilai FN = 30 pada Tabel 4 yang mengonfirmasi bahwa kelas ini paling sering mengalami kesalahan klasifikasi, kemungkinan akibat kemiripan visual dengan labu botol dan mentimun. Secara keseluruhan, model mencapai akurasi 0,96 dengan *macro average* dan *weighted average* untuk presisi, *recall*, dan *F1-score* masing-masing sebesar 0,96, yang menunjukkan kinerja yang konsisten dan seimbang di seluruh 15 kelas tanpa kecenderungan dominasi kelas tertentu.

Dengan demikian, hasil pengujian menunjukkan bahwa akurasi keseluruhan mencapai 96%, yang berarti hanya sekitar 4% dari 3.000 data uji yang tidak diklasifikasikan dengan benar. Dalam angka, sebanyak 130 citra mengalami kesalahan klasifikasi, sedangkan 2.870 citra lainnya berhasil diidentifikasi dan diklasifikasikan dengan tepat.

3.3. Analisis Generalisasi Model

Selisih antara *training accuracy* (92,8%) dan *validation accuracy* (95,83%) yang hanya sekitar 3%, dikombinasikan dengan *testing accuracy* (95,67%) yang mendekati keduanya, mengonfirmasi bahwa model tidak mengalami *overfitting* yang signifikan dan memiliki kemampuan generalisasi yang baik. Meskipun demikian, generalisasi ini masih terbatas pada distribusi *dataset* Kaggle yang bersifat terkontrol. Model belum divalidasi pada citra dari sumber eksternal dengan kondisi pengambilan gambar yang bervariasi, seperti perbedaan pencahayaan, sudut kamera, atau kondisi fisik sayuran. Penelitian lanjutan perlu menguji model pada *dataset* eksternal yang lebih beragam untuk mengonfirmasi kemampuan generalisasi lintas domain, sebagaimana direkomendasikan oleh Carreras (2024) [23].

3.4. Analisis Faktor Kesalahan Klasifikasi

Berdasarkan Tabel 4, tiga kelas dengan tingkat kesalahan tertinggi adalah labu pahit (FN = 30, *recall* = 0,87), waluh (FN = 17), dan kembang kol (FN = 14, *recall* = 0,93). Kesalahan pada kelas labu pahit secara konsisten dikonfirmasi oleh nilai *recall* terendah pada Gambar 7 (indeks 7 = 0,87), yang mengindikasikan bahwa model kerap gagal mengenali labu pahit akibat kemiripan bentuk *elongated* dan warna kehijauan yang serupa dengan labu botol dan mentimun. Kelas kubis (FP = 23) dan terong (FP = 22) menunjukkan tingkat kesalahan positif yang tinggi, yang berarti citra dari kelas lain sering salah diprediksi sebagai kedua kelas tersebut, kemungkinan akibat variasi tingkat kematangan dan kondisi pencahayaan. Fenomena misklasifikasi berbasis kemiripan visual antarkelas ini sejalan dengan temuan Jin *et al.* (2025) pada klasifikasi sayuran dan gulma dalam kondisi lapangan [22].

3.5. Analisis Bias Dataset

Dataset Kaggle yang digunakan memiliki distribusi yang seimbang (200 citra per kelas), sebuah kondisi ideal yang jarang ditemui dalam skenario nyata. Terdapat tiga keterbatasan utama yang perlu dicatat: pertama, seluruh citra menampilkan sayuran tunggal dengan latar belakang yang bersih sehingga kinerja model berpotensi menurun pada citra berlatar belakang kompleks atau dengan kondisi sayuran yang tumpang tindih; kedua, tidak terdapat representasi citra sayuran dalam kondisi rusak atau busuk; ketiga, sumber dataset yang tunggal berpotensi menghasilkan bias distribusi yang tidak merepresentasikan keragaman visual sayuran di kondisi nyata seperti pasar tradisional atau lahan pertanian. Keterbatasan-keterbatasan ini sejalan dengan yang diidentifikasi oleh Karunia *et al.* (2025), yang merekomendasikan penggunaan dataset yang lebih besar dan bersumber dari berbagai kondisi pengambilan gambar [21].

3.6. Perbandingan dengan Metode Lain dan Penelitian Sejenis

Penelitian ini tidak melakukan perbandingan langsung (*head-to-head*) dengan model lain karena dirancang sebagai studi eksplorasi awal yang berfokus pada dua kontribusi utama: membangun arsitektur CNN *from scratch* untuk klasifikasi sayuran berbasis citra dan mengintegrasikannya dengan penyediaan informasi kandungan nutrisi secara otomatis. Di samping itu, keterbatasan sumber daya komputasi membatasi kemampuan melatih arsitektur yang lebih dalam seperti ResNet atau EfficientNet yang memerlukan *hardware* GPU kelas tinggi. Perbandingan langsung yang valid juga mensyaratkan keseragaman dataset, kondisi pelatihan, dan metrik evaluasi yang identik, kondisi yang tidak dapat dipenuhi tanpa melakukan pelatihan ulang seluruh model pembandingan. Meskipun demikian, perbandingan berbasis literatur disajikan pada Tabel 5 sebagai rujukan kontekstual.

Tabel 5. Perbandingan Kinerja dengan Metode Lain dan Penelitian Sejenis

Penelitian / Metode	Dataset	Akurasi	Keterangan
Penelitian ini	15 kelas sayuran, 21.000 citra	95,67%	CNN + penyediaan info nutrisi
Karunia <i>et al.</i> (2025) [21]	15 kelas sayuran, 21.000 citra	93,00%	Metodologi identik; tanpa integrasi nutrisi
Khoiruddin & Tena (2024) [20]	36 kelas buah & sayuran	97,31%	Transfer learning MobileNetV2
Jin <i>et al.</i> (2025) [22]	Sayuran/gulma, citra lapangan	>95,60%	EfficientNet/ResNet, kondisi <i>real-world</i>
Alshammari (2024) [24]	Data tabular, 400 baris 13 fitur	92,92% (ANN lebih baik)	Superioritas ANN atas SVM/KNN secara empiris
Carreras (2024) [23]	Citra histologi medis (3 kelas)	99,70%	CNN <i>transfer learning</i> , rekomendasi validasi lintas domain

Perbandingan paling signifikan secara metodologis adalah dengan Karunia *et al.* (2025) [21] yang menggunakan dataset dan jumlah kelas yang identik. Model dalam penelitian ini mencapai *testing accuracy* 95,67%, melampaui 93,00% milik Karunia *et al.* dengan selisih 2,67 poin persentase, meskipun Karunia *et al.* menggunakan total 31.000 citra 10.000 lebih banyak dari penelitian ini. Peningkatan kinerja ini dicapai melalui optimasi arsitektur delapan lapisan dan augmentasi data, sekaligus disertai integrasi penyediaan informasi kandungan nutrisi yang tidak dimiliki penelitian tersebut.

Dibandingkan dengan *transfer learning*, MobileNetV2 milik Khoiruddin & Tena (2024) [20] mencapai akurasi 97,31% pada 36 kelas dengan memanfaatkan bobot *pre-trained* ImageNet. Selisih akurasi sebesar 1,64 poin persentase menunjukkan bahwa arsitektur CNN *from scratch* yang dioptimalkan mampu mendekati kinerja *transfer learning* tanpa ketergantungan pada bobot eksternal. Jin *et al.* (2025) [22] menguji EfficientNet dan ResNet pada kondisi lapangan yang jauh lebih kompleks dengan variasi latar belakang, pencahayaan, dan keberadaan gulma dan tetap mencapai akurasi di atas 95,6%, yang mengonfirmasi bahwa CNN berbasis konvolusi secara konsisten unggul untuk tugas klasifikasi citra sayuran lintas kondisi.

Alshammari (2024) [24] secara empiris membuktikan bahwa ANN mencapai akurasi tertinggi 92,92% pada klasifikasi gangguan tidur, mengungguli SVM (88,50%), KNN (83,19%), *decision tree* (92,04%), dan *random forest* (91,15%) pada dataset yang sama. Temuan ini mengonfirmasi bahwa pendekatan berbasis jaringan saraf, termasuk CNN, secara struktural lebih unggul dari metode konvensional untuk tugas klasifikasi yang melibatkan pola kompleks dan fitur berdimensi tinggi. Carreras (2024) [23] menunjukkan bahwa CNN yang dilatih pada distribusi data tertentu, dalam hal ini citra histologi, mencapai akurasi 99,7% namun performanya tidak dapat diasumsikan bertahan pada distribusi data yang berbeda tanpa validasi eksplisit, yang memperkuat rekomendasi bahwa model dalam penelitian ini perlu diuji pada dataset eksternal di luar Kaggle untuk mengonfirmasi kemampuan generalisasi lintas domain.

4. KESIMPULAN

Berdasarkan hasil penerapan metode *Convolutional Neural Network* (CNN) untuk klasifikasi jenis sayuran berbasis citra pada *dataset* yang memuat 15 kelas sayuran brokoli, *capsicum*, kacang, kembang kol, kentang, kubis, labu botol, labu pahit, lobak, mentimun, pepaya, terong, tomat, waluh, dan wortel diperoleh kesimpulan sebagai berikut. (1) Model CNN dengan arsitektur *sequential* yang terdiri atas delapan lapisan mampu mengklasifikasikan 15 jenis sayuran berbasis citra digital dengan *training accuracy* 92,8%, *validation accuracy* 95,83%, dan *testing accuracy* 95,67%. Setelah kelas sayuran berhasil diidentifikasi melalui proses klasifikasi citra, model secara otomatis menampilkan informasi kandungan nutrisi yang bersumber dari basis data yang telah disiapkan sebelumnya. (2) Evaluasi kinerja model CNN menggunakan *confusion matrix* menghasilkan akurasi keseluruhan 96%, presisi tertinggi 99%, *recall* tertinggi 100%, dan *F1-score* tertinggi 100%. Hasil ini menunjukkan bahwa model mampu mengklasifikasikan citra sayuran dengan kinerja yang baik dan konsisten di seluruh 15 kelas, serta unggul dibandingkan dengan metode konvensional seperti SVM, KNN, dan ANN tradisional yang memerlukan ekstraksi fitur manual dan tidak optimal untuk data citra berdimensi tinggi.

Dengan demikian, penelitian ini berhasil membuktikan bahwa metode CNN efektif digunakan untuk klasifikasi jenis sayuran berbasis citra dan dapat diintegrasikan dengan penyediaan informasi kandungan nutrisi secara otomatis, sehingga memberikan kontribusi nyata bagi pengembangan model cerdas pendukung gizi masyarakat.

REFERENSI

- [1] S. W. Rhomadona dan M. L. Siagian, "Upaya Peningkatan Kesehatan Sanitasi Keluarga dalam Pencegahan Stunting Melalui Edukasi Tentang Cara Penyimpanan dan Pengolahan Sayuran yang Benar," *Jurnal Pengabdian Masyarakat*, vol. 2, no. 2, pp. 18–25, 2021.
- [2] M. J. Akbar, M. W. Sardjono, M. Cahyanti, dan E. R. Swedia, "Perancangan Aplikasi Mobile untuk Klasifikasi Sayuran Menggunakan Deep Learning Convolutional Neural Network," *Sebatik*, vol. 24, no. 2, pp. 300–306, 2020.
- [3] Kementerian Kesehatan, "Apa Saja Manfaat Sayur-Sayuran?" <https://P2ptm.Kemkes.Go.Id>, diakses pada 3 Juli 2024.
- [4] P. S. Nugroho, "Jenis Kelamin dan Umur Berisiko Terhadap Obesitas pada Remaja di Indonesia," *An-Nadaa: Jurnal Kesehatan Masyarakat*, vol. 7, no. 2, pp. 110–114, 2020.
- [5] L. C. Blekkenhorst, M. Sim, S. Radavelli-Bagatini, N. P. Bondonno, C. P. Bondonno, A. Devine, dan J. R. Lewis, "Cruciferous Vegetable Intake is Inversely Associated with Extensive Abdominal Aortic Calcification in Elderly Women: A Cross-Sectional Study," *British Journal of Nutrition*, vol. 125, no. 3, pp. 337–345, 2021.
- [6] D. Purwitasari, O. P. Putri, dan W. N. Khotimah, "Aturan asosiasi dengan standar storet pada model prediksi parameter pendukung uji kualitas air baku," *Journal of Information Systems Engineering and Business Intelligence*, vol. 1, no. 1, pp. 1–8, 2015.
- [7] F. Marpaung, F. Aulia, dan R. C. Nabila, *Computer Vision dan Pengolahan Citra Digital*. Pustaka Aksara, 2022.
- [8] A. Ridho'i, K. Setyadjit, dan B. Hariadi, "Menentukan Kualitas Buah Apel Malang Berdasarkan Kulitnya Memanfaatkan Pengolahan Citra Digital," *Jurnal Teknik Industri*, vol. 25, no. 2, pp. 1–12, 2022.
- [9] R. Sarno, S. I. Sabilla, D. P. Purbawa, M. Khah, dan H. S. Ardani, *Machine Learning dan Deep Learning Konsep dan Pemrograman Python*. Penerbit Andi, 2022.
- [10] W. Setiawan, *Deep Learning Menggunakan Convolutional Neural Network: Teori dan Aplikasi*. Media Nusa Creative (MNC Publishing), 2021.
- [11] V. Siahaan dan R. H. Sianipar, *Klasifikasi Citra Berbasis Deep Learning Menggunakan Scikit-Learn, TensorFlow, dan Keras dengan Python GUI*. Balige Publishing, 2021.
- [12] A. W. Ebert, "The Role of Vegetable Genetic Resources in Nutrition Security and Vegetable Breeding," *Plants*, vol. 9, no. 6, p. 736, 2020.
- [13] M. R. S. Erwin, A. G. Putrada, dan M. A. Triawan, "Deteksi Hama Ulat pada Tanaman Selada Berbasis Aquaponic Menggunakan CNN (Convolutional Neural Network)," *Eproceedings of Engineering*, vol. 8, no. 5, 2021.
- [14] R. C. Sigitta, R. H. Saputra, dan F. Fathulloh, "Deteksi Penyakit Tomat Melalui Citra Daun Menggunakan Metode Convolutional Neural Network," *Aviation Electronics, Information Technology, Telecommunications, Electricals, Controls*, vol. 5, no. 1, pp. 43–51, 2023.
- [15] A. Wibowo, D. M. C. Hermanto, K. I. Lestari, dan H. Wijoyo, "Deteksi Kematangan Buah Jambu Kristal Berdasarkan Fitur Warna Menggunakan Metode Transformasi Ruang Warna HSV dan K-Nearest Neighbor," *INCODING: Journal of Informatics and Computer Science Engineering*, vol. 1, no. 2, pp. 76–88, 2021.
- [16] M. Zufar dan B. Setiyono, "Convolutional Neural Networks untuk Pengenalan Wajah Secara Real-

- Time," *Jurnal Sains dan Seni ITS*, vol. 5, no. 2, 2016.
- [17] R. D. Ramadhani, A. N. A. Thohari, C. Kartiko, A. Junaidi, T. G. Laksana, dan N. A. S. Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 312–318, 2021.
 - [18] D. M. Powers, "Evaluation: From Precision, Recall And F-Measure To ROC, Informedness, Markedness and Correlation," *Arxiv Preprint Arxiv: 2010.16061*, 2020.
 - [19] J. Han, M. Kamber, dan J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Morgan Kaufmann, 2012.
 - [20] M. Khoiruddin dan S. Tena, "Fruit and Vegetable Classification using Convolutional Neural Network with MobileNetV2," *Journal of Applied Research In Computer Science and Information Systems*, vol. 2, no. 2, pp. 203–210, 2024, doi: 10.61098/jarcis.v2i2.197.
 - [21] W. A. Karunia, S. M. Puspita, D. Rolliawati, dan A. Yusuf, "Classification of Vegetable Types Using the Convolutional Neural Network (CNN) Algorithm," *Paradigma-Jurnal Komputer dan Informatika*, vol. 27, no. 1, pp. 48–54, 2025.
 - [22] H. Jin, K. Han, H. Xia, B. Xu, dan X. Jin, "Detection of weeds in vegetables using image classification neural networks and image processing," *Frontiers in Physics*, vol. 13, p. 1496778, 2025.
 - [23] J. Carreras, "Celiac disease deep learning image classification using convolutional neural networks," *Journal of Imaging*, vol. 10, no. 8, p. 200, 2024, doi: 10.3390/jimaging10080200.
 - [24] T. S. Alshammari, "Applying machine learning algorithms for the classification of sleep disorders," *IEEE Access*, vol. 12, pp. 36110–36121, 2024.
 - [25] M. A. Hasan, T. Bhargav, V. Sandeep, V. S. Reddy, dan R. Ajay, "Image classification using convolutional neural networks," *International Journal of Mechanical Engineering Research and Technology*, vol. 16, no. 2, pp. 173–181, 2024.