

## Analisa Komparatif Klasifikasi Citra Sayuran dengan Algoritma Support Vector Machine dan Convolutional Neural Network

**Ida Wahidah<sup>1\*</sup>, Hadian Mandala Putra<sup>2</sup>, Suhartini<sup>3</sup>, Taufik Akbar<sup>4</sup>**

<sup>1,3</sup>Program Studi Informatika, Universitas Hamzanwadi, Indonesia

<sup>2,4</sup>Program Studi Teknik Komputer, Universitas Hamzanwadi, Indonesia

\*idawahidah@hamzanwadi.ac.id

### Abstrak

Penelitian ini melakukan analisa komparatif antara algoritma *Support Vector Machine* (SVM) dari teknik *machine learning* (pembelajaran mesin) dan algoritma *Convolutional Neural Network* (CNN) dari teknik *deep learning* (pembelajaran mendalam) untuk mengklasifikasikan kategori citra sayuran. Adapun penelitian ini menggunakan pendekatan metode kuantitatif dengan melakukan beberapa skema uji coba dengan beberapa teknik ekstraksi fitur SVM dan arsitektur CNN. Tujuan dari penelitian ini membandingkan tingkat performa, efektivitas serta efisiensi dari algoritma SVM dan CNN. Dataset yang digunakan adalah dataset public yang diakses dari *platform Kaggle* berupa dataset citra sayuran dengan total jumlah citra keseluruhan berjumlah 21.000 citra yang dikategorikan dalam 15 kelas. Hasil skema uji coba yang dilakukan menunjukkan performa algoritma CNN jauh melebihi performa algoritma SVM dalam segi perhitungan akurasi, presisi, recall dan f1-score. Algoritma CNN juga mampu melakukan generalisasi lebih baik dalam memprediksi data citra baru. Performa terbaik dari algoritma SVM ditunjukkan oleh ekstraksi fitur dengan menggunakan Color Histogram dengan akurasi 93%. Untuk algoritma CNN dengan arsitektur *pre-trained* VGG16 dan MobileNetV2 akurasi yang diperoleh sebesar 98% dan 100%. Berdasarkan hasil perbandingan algoritma, CNN memberikan akurasi yang lebih baik dari SVM, dengan demikian penelitian ini bisa dijadikan referensi ilmiah bagi pengembangan sistem klasifikasi citra di bidang pertanian digital maupun yang membutuhkan tingkat akurasi tinggi dan efisiensi pemrosesan yang optimal.

Kata kunci : CNN (Convolutional Neural Network), Deep Learning, Klasifikasi Citra, Machine Learning, SVM (Support Vector Machine).

### Abstract

*This study presents a comparative analysis between the Support Vector Machine (SVM) algorithm, representing machine learning techniques, and the Convolutional Neural Network (CNN) algorithm, representing deep learning techniques, for vegetable image classification. The research adopts a quantitative approach by conducting multiple experimental schemes involving various SVM feature extraction methods and CNN architectures. The objective of this study is to evaluate and compare the performance, effectiveness, and computational efficiency of SVM and CNN algorithms. The dataset used in this study is a publicly available vegetable image dataset obtained from the Kaggle platform, consisting of 21.000 images categorized into 15 classes. The experimental results indicate that CNN significantly outperforms SVM in terms of accuracy, precision, recall, and F1-score. Moreover, CNN demonstrates superior generalization capability in predicting unseen image data. The best performance of the SVM algorithm was achieved using the Color Histogram feature extraction method, yielding an accuracy of 93%. In contrast, CNN models employing pre-trained architectures achieved higher accuracy, with VGG16 and MobileNetV2 obtaining accuracies of 98% and 100%, respectively. Based on the comparative results, CNN provides higher classification accuracy than SVM; therefore, this study can serve as a scientific reference for the development of image classification systems in digital agriculture and other applications requiring high accuracy and efficient computational performance.*

Keywords : CNN (Convolutional Neural Network), Deep Learning, Image Classification, Machine Learning, SVM (Support Vector Machine)..

## 1. Pendahuluan

Perkembangan industri pertanian dan perkebunan menjadi salah satu sumber utama pendukung keberlangsungan kehidupan manusia. Dalam era industri, manusia cenderung ingin memperoleh hasil panen berkualitas dalam jumlah yang mampu mencukupi kebutuhan sehari-hari dari sayuran dan buah-buahan. Sayuran dan buah-buahan memiliki nilai gizi yang tinggi dalam memenuhi kebutuhan manusia. Setiap jenis sayuran dan buah-buahan memiliki karakteristik yang berbeda-beda, baik dari segi bentuk, warna hingga teksturnya<sup>[1]</sup>. Dengan adanya teknologi digitalisasi modern dalam bidang *machine learning* (pembelajaran mesin) dan *deep learning* (pembelajaran mendalam) yang menjadi salah satu bagian dari cabang kecerdasan buatan, petani dapat mengenali jenis sayuran dan buah-buahan secara cepat, tepat dan akurat. Penggunaan teknologi yang lebih modern membantu petani melakukan otomatisasi dalam pekerjaannya memilah dan mengelompokkan jenis sayuran dan buah-buahan yang sama, sehingga mampu menghemat lebih banyak waktu dan tenaga yang diperlukan untuk mengelompokkan jenis sayuran dan buah-buahan yang dihasilkan dari lahan pertanian maupun perkebunan<sup>[2]</sup>.

Klasifikasi menggunakan teknik pembelajaran mesin maupun pembelajaran mendalam telah banyak digunakan dalam era digital maupun

industrialisasi saat ini. *Support Vector Machine* (SVM) merupakan salah satu teknik pembelajaran mesin dan *Convolutional Neural Network* (CNN) adalah algoritma dari teknik pembelajaran mendalam yang mampu mengklasifikasikan citra gambar. SVM adalah teknik pembelajaran mesin yang biasanya digunakan untuk mengklasifikasikan citra dalam jumlah dataset yang kecil sehingga mampu menghasilkan akurasi yang baik. Sementara CNN adalah salah satu algoritma dari teknik pembelajaran mendalam yang digunakan dalam klasifikasi citra dengan dataset yang lebih besar. CNN mampu mengekstraksi fitur-fitur kompleks seperti warna dan tekstur dari suatu citra<sup>[3]</sup>.

Adapun penelitian ini berfokus pada implementasi algoritma *Support Vector Machine* (SVM) dan *Convolutional Neural Network* (CNN) dalam mengklasifikasikan sayuran dan buah-buahan untuk mengetahui tingkat performa dan efektifitas serta efisiensinya. SVM maupun CNN banyak digunakan dalam pemrosesan citra gambar untuk kebutuhan deteksi dan klasifikasi objek<sup>[4]</sup>. Meskipun penelitian klasifikasi citra sayuran telah banyak dilakukan dengan pendekatan *machine learning* dan *deep learning*, beberapa penelitian sebelumnya menggunakan dataset berskala kecil dengan jumlah kelas yang terbatas, dengan hanya menerapkan satu jenis metode klasifikasi tanpa analisis yang komparatif serta mendalam. Selain itu perbandingan

algoritma SVM dengan berbagai teknik ekstraksi fitur dan CNN dengan berbagai arsitektur pada dataset berskala besar masih jarang dilakukan. Oleh karena itu, penelitian ini berfokus untuk mengisi celah beberapa penelitian sebelumnya dengan melakukan analisa komparatif antara SVM dan CNN dalam mengklasifikasikan dataset citra gambar berskala besar dengan banyak kelas secara mendalam dan komprehensif untuk menentukan metode yang lebih unggul.

## **2. Tinjauan Pustaka**

### **2.1. Penelitian Terkait**

Dari penelitian ini, penulis mengangkat beberapa penelitian sebagai referensi dalam memperkaya bahan kajian. Berikut merupakan penelitian beberapa jurnal terkait dengan penelitian yang dilakukan penulis, yaitu; (1) Penelitian berjudul "Klasifikasi Antraknosa dan Buah Busuk pada Citra Cabai Rawit Menggunakan Metode MobileNetV2 dengan SVM", mengkaji penyakit pada tanaman cabai menggunakan klasifikasi untuk mendeteksi penyakit tanaman cabai yang dikategorikan menjadi tiga kondisi yaitu sehat, terinfeksi antraknosa, dan busuk. Klasifikasi yang dilakukan menggunakan MobileNetV2 sebagai input untuk model SVM. Jumlah dataset yang digunakan adalah 1020 dengan 70% data latih, 15% validasi dan 15% untuk uji. Hasil akurasi validasi yang diperoleh sebesar 98% dan akurasi pengujian 100% dengan *F1-Score* 100%.

Keterbatasan pada penelitian ini yaitu pada generasi model yang belum diuji pada model yang lebih kompleks serta terbatas hanya pada tiga kelas [5]. (2) Penelitian yang berjudul "Klasifikasi Jenis Buah Menggunakan Metode CNN", melakukan pengklasifikasian buah-buahan dengan menggunakan CNN dalam mengenali pola citra digital melalui ekstraksi fitur menggunakan lapisan konvolusi dan *pooling*. Dataset yang digunakan diperoleh melalui Kaggle dengan skema 80:20 dengan akurasi 91% dan akurasi untuk skema 70:30 diperoleh sebesar 98%. Keterbatasan penelitian ini terletak pada dataset yang hanya mampu mengklasifikasi 8 jenis buah-buahan [6]. (3) Penelitian berjudul "Klasifikasi Citra Buah Jeruk Mandarin dan Kelapa Menggunakan Algoritma PCA dan Metode K-Nearest Neighbor (KNN)", mengklasifikasikan buah jeruk, mandarin dan strawberi menggunakan *Principal Component Analysis (PCA)* dan *K-Nearest Neighbor (KNN)*. Hasil dari penelitian ini menunjukkan kombinasi *PCA* dan *KNN* mampu memberikan akurasi yang baik pada parameter K tertentu mencapai rata-rata akurasi sebesar 80%. Keterbatasan penelitian ini terletak pada jumlah dataset yang kecil berjumlah 10 citra, tidak cocok digunakan untuk dataset dengan ukuran yang besar [7]. (4) Penelitian berjudul "Perbandingan Algoritma SVM dan CNN menggunakan PCA untuk Klasifikasi Kematangan Jeruk Keprok", menggabungkan *PCA* dan *SVM* dibandingkan

dengan *PCA* dan *CNN* dalam mengklasifikasi tingkat kematangan buah jeruk. Jumlah dataset yang digunakan sebanyak 1715 diambil dari Kaggle. Hasil akurasi dari gabungan *PCA* dan *SV-M* sebesar 98.9% dan untuk akurasi *PCA* – *CNN* sebesar 76.4%. Keterbatasan pada penelitian ini terbatas pada satu jenis dataset [8]. (5) Penelitian berjudul “Klasifikasi Citra Bunga Multikelas Menggunakan Convolutional Neural Network (CNN)”, mengkaji 10 jenis citra bunga dengan total 994 dataset untuk dilakukan klasifikasi. Data dibagi menjadi 798 dan 196 untuk data latih dan validasi. Hasil akurasi validasi yang diperoleh sebesar 72,48% dengan menggunakan *CNN* menandakan akurasi sudah cukup baik dalam mengklasifikasi citra bunga. Keterbatasan penelitian ini terletak pada kurangnya proses *tuning* untuk meningkatkan akurasi [9].

## 2.2. Landasan Teori

### 1. Citra

Citra merupakan representasi visual dari satu atau lebih suatu objek. Citra dibedakan menjadi 3 jenis, biner (monokrom), keabuan (grayscale) dan berwarna. Citra digital terdiri dari Matriks dengan ukuran M kolom dan N baris, yang mana titik temunya disebut piksel (bagian terkecil dari sebuah citra) [10].

### 2. Klasifikasi

Klasifikasi merupakan proses mengelompokkan data berdasarkan kriteria dan kategori tertentu

dengan tujuan memprediksi data baru yang belum diketahui kelasnya. Klasifikasi dapat dilakukan dengan manual atau memanfaatkan teknologi komputasi dengan pembelajaran mesin maupun pembelajaran mendalam [11].

3. *Machine Learning* (Pembelajaran Mesin) merupakan kajian tentang algoritma yang mampu belajar dari sekumpulan data yang diberikan untuk meningkatkan kinerja akurasi pada suatu tugas tertentu [12]. Pembelajaran mesin bekerja dengan cara mengekstraksi pola dari data melalui proses pelatihan, dengan pola yang sudah dilatih untuk melakukan prediksi ataupun klasifikasi. Beberapa diantara algoritma pembelajaran mesin yaitu *K-Nearest Neighbor*, (*KNN*), *Support Vector Machine* (*SVM*), *Random Forest*, dan *Naïve Bayes*.

### 4. *Deep Learning* (Pembelajaran Mendalam)

Pembelajaran mendalam merupakan cabang dari pembelajaran mesin dengan menggunakan jaringan saraf tiruan dengan beberapa lapisan (*deep neural networks*) untuk mempelajari representasi fitur secara otomatis dari kumpulan data yang diberikan. Salah satu model pembelajaran mendalam yaitu *Convolutional Neural Networks* (*CNN*) terbukti efektif dalam pengenalan klasifikasi citra [13].

### 5. *Support Vector Machine* (*SVM*)

*Support Vector Machine* (*SVM*) adalah algoritma klasifikasi pembelajaran mesin. Dalam pembelajaran mesin, *SVM* termasuk dalam

pembelajaran terawasi. SVM memiliki kemampuan untuk memisahkan data dengan dimensi tinggi ke dalam beberapa kelas dengan menggunakan *hyperplane* atau garis pemisah<sup>[14]</sup>.

#### 6. Convolutional Neural Network (CNN)

CNN adalah salah satu algoritma pembelajaran mendalam yang menggunakan lapisan konvolusi untuk mengklasifikasikan data. Algoritma CNN dapat mengekstraksi fitur-fitur kompleks untuk tugas klasifikasi. Lapisan konvolusi pada algoritma CNN dapat disesuaikan dengan kebutuhan untuk meningkatkan tingkat pembelajaran dan akurasi. Algoritma CNN memiliki beberapa arsitektur *pre-trained*, diantaranya LeNet-5, AlexNet, VGG, GoogLeNet, ResNet, SqueezeNet, dan MobileNet<sup>[15][16]</sup>.

#### 7. Metrik Evaluasi

Dalam penelitian ini, metrik evaluasi yang digunakan untuk mengukur kualitas model, baik untuk pembelajaran mesin maupun pembelajaran mendalam<sup>[17]</sup> yaitu:

- Akurasi: Jumlah data benar terhadap total data

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

- Presisi: Kemampuan model memprediksi kelas

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

- Recall: Kemampuan model menemukan semua data yang relevan

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

- F1-Score: rata-rata harmonis presisi dan recall

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

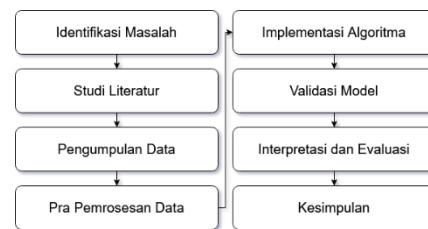
Keterangan:

- TP (*True Positive*): Model memprediksi positif dengan benar.
- TN (*True Negative*): Model memprediksi negatif dengan benar.
- FP (*False Positive*): Model salah memprediksi positif, padahal label negatif.
- FN (*False Negative*): Model gagal memprediksi positif, padahal label positif.

### 3. Metode Penelitian

#### 3.1. Metode dan Tahapan Penelitian

Penelitian ini menggunakan pendekatan metode penelitian kuantitatif untuk mengklasifikasi beberapa jenis sayuran dan buah-buahan dengan menggunakan teknik pembelajaran mesin dengan algoritma SVM maupun pembelajaran mendalam dengan algoritma CNN. Adapun tahapan dalam penelitian ini:



Gambar 1. Tahapan Penelitian

#### 3.2. Lokasi Penelitian

Penelitian ini dilakukan di Laboratorium 5 Fakultas Teknik Universitas Hamzanwadi.

### 3.3. Sumber Data Penelitian

Penelitian ini menggunakan data publik yang bersumber dari platform Kaggle ([www.kaggle.com/datasets/misrakahmed/vegetable-image-dataset](http://www.kaggle.com/datasets/misrakahmed/vegetable-image-dataset)) [18] dengan total data sebanyak 21.000 citra sayuran dalam 15 kelas. Data masing-masing kelas berjumlah 1400. Distribusi data citra sayuran ditunjukkan pada gambar 2.

tag	
Bean	1400
Bitter_Gourd	1400
Bottle_Gourd	1400
Brinjal	1400
Broccoli	1400
Cabbage	1400
Capsicum	1400
Carrot	1400
Cauliflower	1400
Cucumber	1400
Papaya	1400
Potato	1400
Pumpkin	1400
Radish	1400
Tomato	1400

Gambar 2. Distribusi Citra Sayuran dan Buah

### 3.4. Teknik Analisa Data

Penelitian ini menggunakan algoritma *SVM* dan *CNN* dalam membuat model prediksi terhadap citra sayuran. Pra pemrosesan data dilakukan terlebih dahulu tergantung pada algoritma yang digunakan. Kedua model prediksi dioptimasi sampai mendapatkan hasil yang terbaik dan dibandingkan performanya dengan metrik evaluasi akurasi, presisi, *recall* dan *f1-score*. Adapun tahapan yang dilakukan sampai evaluasi, yaitu:

#### 1. Pra Pemrosesan Data

Tahap ini dilakukan pra pemrosesan data, meliputi resize ukuran citra menjadi seragam, normalisasi nilai piksel, selanjutnya proses augmentasi citra yang meliputi rotasi, pembalikan,

perbesaran dan khusus untuk algoritma *SVM* dilakukan ekstraksi fitur. Selanjutnya, data dipisah menjadi data latih, data uji, dan data validasi dengan beberapa proporsi kombinasi.

#### 2. Pelatihan Model

Tahap ini melatih model terbaik dengan menggunakan dataset sayuran untuk bisa memprediksi/mengklasifikasi citra sayuran. Model dihasilkan dengan menggunakan algoritma *SVM* dan *CNN*. Model selanjutnya diuji dan divalidasi terhadap citra baru.

#### 3. Evaluasi Model

Tahap ini, model yang sudah dilatih diuji performanya dengan menggunakan metrik uji akurasi, presisi, *recall* dan *f1-score*. Semakin tinggi akurasi dan *f1-score* maka semakin baik model memberikan prediksi.

## 4. Hasil dan Pembahasan

### 4.1. Hasil Penelitian

Berdasarkan tahapan penelitian yang dilakukan, tahap pertama yaitu pra pemrosesan dataset untuk 2 algoritma yang diimplementasikan, yaitu *Support Vector Machine (SVM)* dan *Convolutional Neural Network (CNN)*.

#### 1. Algoritma *Support Vector Machine (SVM)*

Tahapan pertama untuk algoritma *SVM* adalah pembuatan fungsi ekstraksi fitur (HOG, COLOR, GLCM, SIFT) dari dataset untuk input algoritma *SVM*. Selanjutnya citra dinormalisasi untuk pelatihan model berdasarkan 4 jenis ekstraksi

fitur. Tahapan berikutnya adalah pelatihan dataset untuk mendapatkan model terbaik berdasarkan fungsi ekstraksi fitur. Berdasarkan hasil pelatihan model diperoleh kombinasi parameter terbaik dari pencarian kombinasi kernel pada algoritma SVM, didapatkan kernel *Radial Basis Function (RBF)* sebagai parameter terbaik dari fitur GLCM, SIFT dan COLOR dan kernel Linear untuk fitur HOG. Data *classification report* pelatihan dengan masing-masing fitur dan kernel terbaik pada algoritma SVM diperoleh hasil akurasi, presisi, recall dan f1-score ditunjukkan pada tabel 1.

Tabel 1. Perbandingan Hasil *Classification Report* dengan Algoritma SVM

Fitur	Acc	Pre	Rec	F1-Score
<b>HOG</b>	0.68	0.68	0.68	0.68
<b>GLCM</b>	0.44	0.45	0.44	0.43
<b>SIFT</b>	0.85	0.87	0.85	0.85
<b>Color</b>	0.93	0.93	0.93	0.93

Hasil pelatihan model terbaik ditunjukkan oleh fitur *color histogram* (COLOR) dengan akurasi hasil pelatihan sebesar 93% (0.93) dan F1-Score sebesar 93% (0.93). Hal ini menunjukkan hasil yang diperoleh sudah bagus dengan nilai akurasi yang tinggi dibandingkan dengan fitur lainnya. Tahap berikutnya pada algoritma SVM adalah memvalidasi data baru diluar data latih dan data uji yang digunakan pada saat pelatihan model. Gambar 3,4,5, dan 6 menunjukkan hasil prediksi dari model yang sudah dilatih.

• Prediksi gambar baru menggunakan model HOG ...

Ekstraksi HOG: 100% |██████████| 3000/3000 [00:22<00:00, 136.25it/s]

Hasil Prediksi (5 sampel pertama):

True_Label	Predicted_Label	Confidence
0	Bean	0.350351
1	Bean	0.228185
2	Cucumber	0.572151
3	Radish	0.369975
4	Cucumber	0.304668

Gambar 3. Hasil Prediksi Citra Baru dengan Fitur HOG

Berdasarkan hasil prediksi citra baru yang diuji menggunakan model SVM fitur HOG, hasil prediksi menunjukkan bahwa 5 sampel, model hanya memprediksi citra baru sesuai dengan label aslinya sebanyak 1 sampel. Hal ini menunjukkan model dengan fitur HOG tidak relevan dalam mendeteksi citra sayuran pada penelitian ini.

• Prediksi gambar baru menggunakan model Color ...

Ekstraksi Color Histogram: 100% |██████████| 3000/3000 [00:00<00:00, 1448.633it/s]

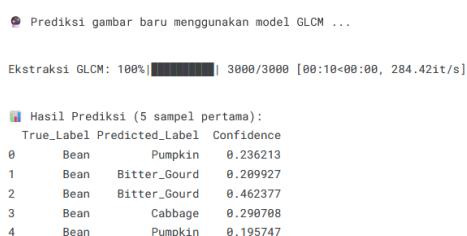
Hasil Prediksi (5 sampel pertama):

True_Label	Predicted_Label	Confidence
0	Bean	0.999140
1	Bean	0.959559
2	Bean	0.925589
3	Bean	0.253337
4	Pumpkin	0.372173

Gambar 4. Hasil Prediksi Citra Baru dengan Fitur Color Histogram

Gambar 4 menunjukkan model SVM dengan fitur *color histogram* (COLOR) memprediksi citra baru dengan tingkat keberhasilan 4 dari 5 sampel, Hal ini menunjukkan model COLOR dengan akurasi 93% mampu memprediksi data citra baru meski terdapat 1 data diprediksi tidak sesuai dengan label. Adapun tingkat *confidence* (kepercayaan) hanya sebesar 0.38 (38%) menunjukkan

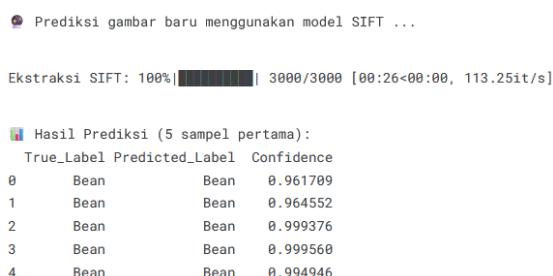
keyakinan model rendah terhadap satu data yang tidak sesuai dengan label.



**Gambar 5. Hasil Prediksi Citra Baru dengan Fitur GLCM**

Gambar 5 menunjukkan model *SVM* dengan fitur *GLCM* tidak mampu melakukan prediksi citra baru, hal ini sesuai dengan akurasi yang hanya sebesar 44%.

Selanjutnya untuk model *SVM* dengan fitur *SIFT* mampu memprediksi keseluruhan sampel dengan sangat baik. Model memprediksi data citra baru dengan tingkat keyakinan semua data sampel berada pada angka diatas 90%. Hasil prediksi ditunjukkan pada gambar 6.



**Gambar 6. Hasil Prediksi Citra Baru dengan Fitur SIFT**

## 2. Algoritma *Convolutional Neural Network*

Pada bagian ini menjelaskan tahapan pra pemrosesan dataset, pelatihan dan skema uji citra dengan menggunakan algoritma *CNN*. Tahapan pra pemrosesan dataset dilakukan dengan

mereduksi ukuran citra secara seragam, selanjutnya normalisasi citra dan proses augmentasi citra sebagai input pada layer konvolusi pada algoritma *CNN*. Setelah tahap pra pemrosesan dataset, dilakukan pelatihan model berdasarkan arsitektur algoritma *CNN* yang dirancang dalam penelitian ini dibandingkan dengan hasil pelatihan beberapa arsitektur yang sudah ada. Algoritma *CNN* yang digunakan sebagai pembanding dari arsitektur algoritma *CNN* sederhana yang dikembangkan pada penelitian ini yaitu *VGG16* dan *MobileNetV2*. Pelatihan model yang dilakukan menerapkan parameter *tuning* untuk mencegah terjadinya *overfitting* dan *underfitting*. *Overfitting* adalah kondisi dimana model dilatih terlalu lama sehingga menghasilkan akurasi yang tinggi tetapi model tidak mampu memprediksi data baru atau menggeneralisasi data baru ke dalam kelas yang sesuai. Sedangkan *underfitting* terjadi saat pelatihan, model yang dihasilkan memiliki performa serta akurasi yang rendah, sehingga model tidak mampu memprediksi data baru [19].

**Tabel 2. Perbandingan Hasil *Classification Report* dengan Algoritma CNN**

Model	Acc	Pre	Rec	F1-Sco
<b>SimpleCNN</b>	0.93	0.94	0.93	0.93
<b>VGG16</b>	0.98	0.98	0.98	0.98
<b>MobileNetV2</b>	1.00	1.00	1.00	1.00

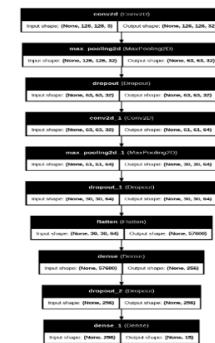
Tabel 2 menunjukkan model *CNN* dengan arsitektur *pre-trained* seperti *MobileNetV2*, *VGG16*. *MobileNetV2* menjadi model terbaik

dibandingkan arsitektur VGG16 dan *SimpleCNN*. VGG16 mampu melakukan ekstraksi fitur secara mendalam pada pengolahan citra, sedangkan *MobileNetV2* memiliki kemampuan pengolahan citra dengan efisiensi komputasi yang tinggi dengan sumber daya yang terbatas seperti penggunaan pada perangkat mobile [20]. Sedangkan *SimpleCNN* adalah arsitektur kustom yang digunakan untuk kebutuhan penelitian ini. Gambar 7 menunjukkan hasil pelatihan model dan prediksi *SimpleCNN*, bahwa dari 5 sampel yang diambil secara acak dari dataset validation menunjukkan konsistensi arsitektur *SimpleCNN* dalam memprediksi citra baru dengan nilai kepercayaan (*confidence*) 0.99 (99%) dengan satu citra yang diprediksi dengan nilai kepercayaan 0.75 (75%) pada citra baru dengan kelas *cucumber*. Hal ini menunjukkan model *SimpleCNN* memiliki akurasi dan performa yang baik serta mampu mengenali citra baru yang sesuai dengan kelasnya.

Hasil Prediksi 5 Sampel pertama:				
	Filename	True_Label	Predicted_Label	Confidence
1801	Cucumber/1202.jpg	Cucumber	Cucumber	0.997350
1190	Cabbage/1392.jpg	Cabbage	Cabbage	0.999424
1817	Cucumber/1218.jpg	Cucumber	Cucumber	0.759787
251	Bitter_Gourd/1052.jpg	Bitter_Gourd	Bitter_Gourd	0.990072
2505	Pumpkin/1306.jpg	Pumpkin	Pumpkin	0.999924

**Gambar 7. Hasil Prediksi Citra Baru Arsitektur *SimpleCNN***

Adapun arsitektur untuk model *SimpleCNN* ditunjukkan pada gambar 8.



**Gambar 8. Arsitektur *SimpleCNN***

Berdasarkan gambar 8, arsitektur *SimpleCNN* ini dirancang untuk mengklasifikasi citra sayuran. Model terdiri dari dua blok konvolusi (*Conv2D* dan *MaxPooling2D*) diikuti oleh lapisan *Flatten* dan dua lapisan *Dense*. Penggunaan *dropout* dalam arsitektur ini untuk mencegah terjadinya *overfitting*. Lapisan *output dense* (15) menunjukkan model bertujuan mengklasifikasikan citra input ke dalam 15 kategori berbeda.

Hasil Prediksi 5 Sampel pertama:				
	Filename	True_Label	Predicted_Label	Confidence
1801	Cucumber/1202.jpg	Cucumber	Cucumber	1.000000
1190	Cabbage/1392.jpg	Cabbage	Cabbage	1.000000
1817	Cucumber/1218.jpg	Cucumber	Cucumber	1.000000
251	Bitter_Gourd/1052.jpg	Bitter_Gourd	Bitter_Gourd	1.000000
2505	Pumpkin/1306.jpg	Pumpkin	Pumpkin	1.000000

**Gambar 9. Hasil Prediksi Citra Baru Arsitektur VGG16**

Gambar 9 menunjukkan arsitektur VGG16 memberikan hasil akurasi dan performa yang konsisten dengan tingkat kepercayaan hasil prediksi citra baru dengan angka 1.00 (100%) dan diprediksi sesuai dengan kategori.

Hasil Prediksi 5 Sampel pertama:				
	Filename	True_Label	Predicted_Label	Confidence
1801	Cucumber/1202.jpg	Cucumber	Cucumber	1.000000
1190	Cabbage/1392.jpg	Cabbage	Cabbage	1.000000
1817	Cucumber/1218.jpg	Cucumber	Cucumber	0.999983
251	Bitter_Gourd/1052.jpg	Bitter_Gourd	Bitter_Gourd	1.000000
2505	Pumpkin/1306.jpg	Pumpkin	Pumpkin	1.000000

**Gambar 10. Hasil Prediksi Citra Baru Arsitektur MobileNetV2**

Gambar 10 menunjukkan prediksi citra baru dari 5 sampel acak, menggunakan arsitektur *MobileNetV2* berhasil memprediksi sampel acak sesuai dengan kategorinya. Hal ini ditunjukkan dari konsistensi akurasi dan performa hasil prediksi citra baru yang menunjukkan angka kepercayaan 0.99 – 1.00 (99% – 100 %).

#### 4.2. Pembahasan

Berdasarkan hasil yang telah didapatkan, dari pelatihan model algoritma *Support Vector Machine (SVM)* dengan beberapa teknik ekstraksi fitur dibandingkan dengan algoritma *Convolutional Neural Network (CNN)* dengan beberapa arsitektur. Kedua algoritma memberikan hasil perhitungan akurasi, presisi, *recall* dan *f1-score* yang berbeda. Pada model *SVM*, hasil performa terbaik didapatkan dari penggunaan fitur *Color Histogram (COLOR)* dengan nilai akurasi, presisi, *recall* dan *f1-score* sebesar 93%. Hal ini menunjukkan karakteristik warna merupakan fitur dominan dalam memprediksi citra sayuran meski pada prediksi 1 dari 5 citra baru terdapat sampel terprediksi tidak sesuai dengan kelasnya. Fitur *SIFT* juga memberikan performa yang baik dengan akurasi 85% dan mampu memprediksi 5 sampel baru sesuai dengan kelas asli. Sedangkan fitur *HOG* dan *GLCM* menghasilkan akurasi model yang rendah dan prediksi yang citra baru tidak sesuai dengan kelas asli. Performa dari algoritma *SVM*

sangat bergantung pada kualitas dan relevansi ekstraksi fitur, selain itu proses ekstraksi dilakukan secara manual sehingga membutuhkan sumber daya komputasi terutama dalam penggunaan *Central Processing Unit (CPU)* yang lebih tinggi dengan waktu komputasi yang lebih tinggi tergantung pada jumlah dataset yang digunakan pada saat proses pelatihan, hal ini dikarenakan konsep *SVM* melakukan pencarian *hyperplane* (garis pemisah) antara kelas satu dengan lainnya, sehingga semakin banyak jumlah data, maka semakin kompleks proses pencarian dan semakin tinggi waktu komputasi yang dibutuhkan. Adapun pada beberapa penelitian sebelumnya [5],[8], algoritma *SVM* mampu memberikan performa baik dalam klasifikasi untuk dataset dengan ukuran kecil 1000-2000 dataset citra. Sedangkan, algoritma *CNN* menunjukkan performa yang lebih tinggi dan lebih unggul dibandingkan algoritma *SVM*. Terbukti dari hasil *classification report* yang berada diatas 90% untuk semua arsitektur. Arsitektur *SimpleCNN* dengan akurasi 93%, setara dengan hasil terbaik algoritma *SVM* dengan fitur *Color Histogram*. Sedangkan untuk arsitektur *pre-trained VGG16* dan *MobileNetV2* menghasilkan akurasi yang lebih tinggi dibandingkan dengan *SimpleCNN*, dengan nilai akurasi sebesar 98% dan 100%. Hal ini membuktikan algoritma *CNN* mampu melakukan proses ekstraksi fitur citra secara otomatis dengan lebih baik dari algoritma *SVM*,

baik dari segi warna, tekstur tanpa perlu ekstraksi manual seperti pada algoritma SVM. Jika dibandingkan dengan algoritma SVM performa CNN jauh lebih baik terutama dari akurasi, akan tetapi dari penggunaan sumber daya algoritma CNN membutuhkan sumber daya komputasi yang lebih banyak yaitu *CPU* dan *GPU* serta waktu komputasi yang lebih lama bergantung pada arsitektur serta jumlah *epoch* saat proses pelatihan dilakukan, serta penerapan parameter *tuning* agar tidak terjadinya *overfitting* maupun *underfitting*. Walaupun demikian, hasil prediksi menunjukkan performa yang signifikan baik pada arsitektur *SimpleCNN*, *VGG16* dan *MobileNetV2*. Berdasarkan hasil tersebut dapat disimpulkan bahwa CNN memiliki performa yang lebih baik dan lebih unggul dibandingkan SVM dalam kemampuan menggeneralisasi model terhadap citra baru dan memiliki akurasi lebih baik secara keseluruhan.

## 5. Kesimpulan

Penelitian ini bertujuan membandingkan performa, efektivitas, dan efisiensi algoritma SVM dan CNN dalam klasifikasi citra sayuran multikelas. Hasil penelitian menunjukkan bahwa CNN secara konsisten memiliki performa yang lebih unggul dibandingkan SVM pada seluruh metrik evaluasi, yaitu akurasi, presisi, recall, dan *f1-score*. Temuan ini menjawab research gap terkait minimnya kajian komparatif yang

komprehensif antara SVM dan CNN pada dataset citra sayuran multikelas berskala besar. Kontribusi utama penelitian ini terletak pada analisis komparatif antara SVM dengan berbagai teknik ekstraksi fitur dan CNN dengan beberapa arsitektur, baik *pre-trained* maupun yang dikembangkan khusus. Hasil eksperimen menunjukkan CNN lebih stabil dan unggul, dengan akurasi tertinggi dicapai oleh MobileNetV2 sebesar 100%, sedangkan SVM terbaik mencapai akurasi 93% menggunakan fitur *Color Histogram*. Oleh karena itu, CNN direkomendasikan untuk klasifikasi citra berskala besar dan kompleks, sementara SVM tetap relevan untuk dataset kecil hingga menengah dengan keterbatasan sumber daya komputasi.

## 6. Daftar Pustaka

- [1] D. Hidayati and A. Ramadhanu, "Implementasi K-Means Clustering dan Teknik Pengolahan Citra Dalam Klasifikasi Buah Kiwi dan Sawo," *J. Ilm. Media Sisfo*, vol. 19, no. 1, pp. 78–85, Apr. 2025, doi: 10.33998/mediasisfo.2025.19.1.2312.
- [2] I. M. Azantha, "Klasifikasi Citra Jenis Buah Dan Sayuran Menggunakan Algoritma Yolov11," Universitas Sriwijaya, 2025.
- [3] P. A. Ilahi, R. Toyib, Y. Reswan, and A. Sonita, "Kematangan Serta Mengukur Kandungan Vitamin C Jeruk Gerga Menggunakan Citra Digital," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 5007–5013, 2025.
- [4] N. Nurafya and A. Y. Chandra, "Analisis Performa Akurasi Klasifikasi Citra Jenis Sayur Salada Menggunakan Arsitektur VGG16, Xception dan NasNetMobile," *J.*

- Media Inform. Budidarma*, vol. 8, no. 3, p. 1240, 2024, doi: 10.30865/mib.v8i3.7661.
- [5] A. C. Satyo Nugroho and O. Suria, "Klasifikasi Antraktikosan Dan Buah Busuk Pada Citra Cabai Rawit Menggunakan Metode Mobilenetv2 Dengan SVM," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 657–666, Jul. 2025, doi: 10.36341/rabit.v10i2.6341.
- [6] K. Jenis, B. Menggunakan, M. Cnn, I. Heidiani Ikasari, P. Rosyani, and R. Amalia, "Klasifikasi Jenis Buah Menggunakan Metode CNN," vol. 4, no. 2, pp. 5451–5458, 2025.
- [7] Adinda Syalsabila, R. Saputra, Ridwan Sutri, Riyandri Saputra, and R. Sopia, "Klasifikasi Citra Buah Jeruk Mandarin dan Kelapa Menggunakan Algoritma PCA dan Metode K-Nearest Neighbor (KNN)," *JPG J. Pendidik. Guru*, vol. 6, no. 2, pp. 263–270, 2025, doi: 10.32832/jpg.v6i2.19351.
- [8] S. Sunarso, C. Chairani, J. Triloka, and R. Kurniawan, "Perbandingan Algoritma SVM dan CNN menggunakan PCA untuk Klasifikasi Kematangan Jeruk Keprok," vol. 3, no. 2, pp. 203–221, 2025.
- [9] R. Ihza Yuzar Vianda, P. Anjarwati, H. Akbar Pratama, R. Maulana Akbar, and R. Dwi Irawan, "Klasifikasi Citra Bunga Multikelas Menggunakan Convolutional Neural Network (CNN)," *Pros. Semin. Nas. Teknol. Inf. dan Bisnis*, vol. 6, no. 1, pp. 367–376, Jul. 2025, doi: 10.47701/0d10j421.
- [10] Ahmad Fariz Fuady, Dwiky Oldi Amsyah, Muhammad Farhan, Rusma Riansyah, and M. Dayyan Dhiyaul Haq, "Implementasi Algoritma Convolutional Neural Network (CNN) untuk Pengenalan dan Klasifikasi Buah Berdasarkan Citra Digital," *J. Publ. Ilmu Komput. dan Multimed.*, vol. 4, no. 2, pp. 148–159, 2025, doi: 10.55606/jupikom.v4i2.4116.
- [11] Imam Fathurrahman, Mahpuz, Muhammad Djamaluddin, Lalu Kerta Wijaya, and Ida Wahidah, "Pengembangan Model Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Kulit Berbasis Citra Digital" *Infotek J. Inform. dan Teknol.*, vol. 8, no. 1, pp. 298–308, 2025.
- [12] S. Marsland, *MACHINE Learning - An Algorithmic Perspective, Second Edition*. New York: CRC Press, 2015. doi: 3034611668, 9783034611664.
- [13] I. Goodfellow, Y. Bengio, and A. Courville, "Deep Learning," p. 800, 2013.
- [14] Dwi Utami, Fathoni Dwiatmoko, and Nuari Anisa Sivi, "Analisis Pengaruh Bayesian Optimization Terhadap Kinerja SVM Dalam Prediksi Penyakit Diabetes," *Infotek J. Inform. dan Teknol.*, vol. 8, no. 1, pp. 140–150, 2025, doi: 10.29408/jit.v8i1.28468.
- [15] H. Sulaiman, Y. Yuliani, Yanto, I. Al Farobi, and K. Panggalih, "Penerapan Model CRISP-DM Untuk Klasifikasi Tumor Otak Menggunakan Algoritma CNN," *Infotek J. Inform. dan Teknol.*, vol. 8, no. 2, pp. 469–476, Jul. 2025, doi: 10.29408/jit.v8i2.31014.
- [16] D. Banu and D. Hanggoro, "Analisis Komparatif Arsitektur Deep Learning Untuk Aplikasi Computer Vision : Studi Literature Review," vol. 4, no. 2, pp. 1001–1008, 2025.
- [17] O. Rainio, J. Teuho, and R. Klén, "Evaluation metrics and statistical tests for machine learning," *Sci. Rep.*, vol. 14, no. 1, pp. 1–14, 2024, doi: 10.1038/s41598-024-56706-x.
- [18] M. I. Ahmed and S. M. Mamun, "Vegetable Image Dataset," 2021, *Kaggle*. doi: 10.34740/KAGGLE/DSV/2965251.
- [19] G. Simon and C. Aliferis, *Artificial Intelligence and Machine Learning in Health Care and Medical Sciences*. 2024.
- [20] M. B. Kurniawan and E. Utami, "Perbandingan Kinerja ResNet50, VGG16, dan MobileNetV2 untuk Klasifikasi Tumor Otak pada Citra MRI," *J. Sist. Inf.*, vol. 14, no. 2, pp. 767–777, 2025.