

# KLASIFIKASI TINGKAT KEMATANGAN CABAI MERAH KERITING MENGGUNAKAN SVM MULTICLASS BERDASARKAN EKSTRAKSI FITUR WARNA

Irma<sup>1</sup>, Mutmainnah Muchtar<sup>2\*</sup>, Rabiah Adawiyah<sup>3</sup>, Sarimuhammad<sup>4</sup>

<sup>1,2,4</sup>Program Studi Ilmu Komputer, FTI USN Kolaka, Jl. Pemuda Tahoa No.339, Kolaka, Sultra

<sup>3</sup>Program Studi Sistem Informasi, FTI USN Kolaka, Jl. Pemuda Tahoa No.339, Kolaka, Sultra

Received: 23 Mei 2024

Accepted: 31 Juli 2024

Published: 7 Agustus 2024

## Keywords:

Capsicum annuum L;  
classification;  
color feature;  
SVM Multiclass.

## Correspondent Email:

muchtarmutmainnah@gmail.com

**Abstrak.** Pemanfaatan pengolahan citra digital memiliki potensi besar dalam klasifikasi kematangan cabai merah keriting (*Capsicum annuum* L.). Penelitian ini bertujuan untuk mengembangkan metode klasifikasi otomatis menggunakan Support Vector Machine (SVM) multiclass dengan kernel linear. Data citra cabai yang diakuisisi menggunakan kamera smartphone dibagi menjadi tiga kelas: matang, mentah, dan setengah matang. Fitur mean, variance, dan range dari ruang warna RGB diekstraksi untuk digunakan sebagai data pelatihan dan pengujian. Pengujian dilakukan dengan membagi data latih dan uji serta menggunakan 10-fold cross validation. Hasil menunjukkan akurasi klasifikasi mencapai 98,33%. Penggunaan kombinasi fitur mean, variance, dan range terbukti meningkatkan keakuratan dibandingkan penggunaan fitur tunggal. Penelitian ini menunjukkan bahwa metode yang dikembangkan efektif dan dapat diaplikasikan dalam sistem klasifikasi otomatis untuk mendukung sektor pertanian.

**Abstract.** The utilization of digital image processing holds significant potential for classifying the ripeness of curly red peppers (*Capsicum annuum* L.). This study aims to develop an automatic classification method using multiclass Support Vector Machine (SVM) with a linear kernel. Images of peppers, captured using a smartphone camera, were categorized into three classes: ripe, unripe, and semi-ripe. Features such as mean, variance, and range from the RGB color space were extracted for training and testing data. Testing was conducted by dividing the data into training and test sets and employing 10-fold cross-validation. Results demonstrated a classification accuracy of 98.33%. The combination of mean, variance, and range features significantly improved accuracy compared to single features. This research demonstrates the effectiveness of the developed method and its applicability in automated classification systems to support the agricultural sector.

## 1. PENDAHULUAN

Cabai merah keriting (*Capsicum annuum* L.) merupakan salah satu komoditas pertanian yang sangat penting di Indonesia, banyak digunakan dalam berbagai masakan[1]. Tingkat kematangan cabai memainkan peran penting

dalam menentukan kualitas dan rasa produk akhir yang dihasilkan. Oleh karena itu, klasifikasi tingkat kematangan cabai secara akurat sangat diperlukan untuk mendukung proses produksi dan distribusi yang efisien[2].

Dalam beberapa tahun terakhir, teknologi pengolahan citra digital telah banyak digunakan dalam bidang pertanian untuk membantu proses identifikasi dan klasifikasi berbagai produk pertanian[3]–[6]. Salah satu pendekatan yang populer adalah penggunaan ekstraksi fitur warna dari citra yang diambil menggunakan kamera, yang kemudian dianalisis dengan metode machine learning seperti Support Vector Machine (SVM)[7], [8].

Berbagai penelitian telah dilakukan untuk mengklasifikasikan tingkat kematangan buah dan sayuran menggunakan metode pengolahan citra digital dan machine learning[9]. Misalnya, penelitian oleh Liantoni dan Annisa [5] menggunakan ekstraksi fitur warna HSV untuk mengklasifikasikan kematangan cabai rawit dengan metode Fuzzy K-Nearest Neighbor (Fuzzy KNN), mencapai akurasi 86,66%. Sementara itu, penelitian oleh Rahman et al. [10] menggunakan KNN dan teknik ekstraksi fitur warna serupa untuk mengklasifikasikan kematangan buah mangga, dengan *software* Matlab mencapai akurasi tertinggi 80%. Begitu pula dengan Hanafi et al. [11] yang menerapkan metode KNN dalam klasifikasi kematangan buah alpukat berdasarkan fitur *mean* dari warna RGB, dengan akurasi 78,57%.

Penelitian oleh Anggraeni dan Fadlil [2] menerapkan City Block Distance dalam sistem identifikasi jenis cabai *Capsicum annuum* L. dengan akurasi tertinggi sebesar 93%. Purwaningsih et al. [12] menerapkan metode CNN (Convolutional Neural Network) untuk klasifikasi jenis cabai merah dan memperoleh akurasi sebesar 80% untuk data uji yang digunakan serta 97,14% untuk data latih. Meskipun CNN menunjukkan hasil yang baik, metode ini membutuhkan komputasi yang lebih tinggi dan data yang lebih besar dibandingkan dengan SVM [13]. Oleh karena itu, penelitian ini memilih SVM *multiclass* sebagai metode yang efisien untuk klasifikasi tingkat kematangan cabai merah keriting, dengan harapan dapat mencapai akurasi yang tinggi dengan kebutuhan komputasi yang lebih rendah.

Penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan cabai merah keriting menjadi tiga kelas: matang, mentah, dan setengah matang. Metode klasifikasi yang diusulkan adalah SVM *multiclass*[14], dengan fitur yang diekstraksi

dari kanal warna citra, yaitu *mean*, *variance*, dan *range* dari kanal R, G, dan B. Ekstraksi fitur warna dari kanal R, G, B, memungkinkan sistem untuk menangkap informasi warna yang signifikan terkait dengan tingkat kematangan cabai. Kombinasi ini memungkinkan identifikasi yang lebih akurat dibandingkan dengan metode berbasis fitur tunggal. Selain itu, metode SVM *multiclass* dikenal karena kemampuannya dalam menangani masalah klasifikasi dengan kelas yang banyak, serta efisiensi komputasinya. Dengan demikian, pendekatan ini berpotensi untuk digunakan dalam aplikasi praktis di bidang pertanian, khususnya untuk proses sortasi otomatis dalam industri pengolahan cabai. Implementasi sistem ini diharapkan dapat meningkatkan efisiensi dan akurasi dalam penanganan produk cabai merah keriting, serta memberikan manfaat ekonomi yang signifikan bagi para petani dan pelaku industri. Penelitian ini diharapkan dapat menjadi dasar bagi pengembangan sistem klasifikasi kematangan cabai yang lebih efisien dan akurat, serta mendorong penelitian lebih lanjut dalam penerapan teknologi pengolahan citra dan *machine learning* di sektor pertanian.

## 2. TINJAUAN PUSTAKA

### 2.1. Cabai Merah Keriting

Cabai merah keriting (*Capsicum annuum* L.) adalah varietas cabai yang banyak dibudidayakan dan digunakan di Indonesia. Cabai ini memiliki bentuk yang panjang dan keriting dengan rasa yang pedas[15]. Warna cabai berubah seiring dengan tingkat kematangannya, dari hijau saat masih mentah, oranye atau hijau kemerahan saat setengah matang, hingga merah cerah saat matang sepenuhnya. Cabai merah keriting tidak hanya digunakan sebagai bumbu masakan tetapi juga memiliki nilai ekonomi tinggi karena permintaannya yang stabil sepanjang tahun.



Gambar 1. *Capsicum annuum* L.[16]

Pengklasifikasian cabai merah keriting tradisional biasanya dilakukan secara manual

berdasarkan warna dan tekstur, membutuhkan ketelitian dan pengalaman manusia. Namun, metode ini kurang efisien dan rentan terhadap kesalahan manusia, terutama dalam skala besar. Sebagai alternatif, teknologi pengolahan citra digital dan algoritma *machine learning* telah digunakan untuk mengotomatisasi proses klasifikasi. Pendekatan ini dapat meningkatkan akurasi dan efisiensi klasifikasi, meskipun membutuhkan investasi awal dalam perangkat keras dan perangkat lunak, serta pemahaman teknis untuk pengoperasiannya.

## 2.2. Ruang Warna RGB

Dalam model warna RGB, warna dibuat dengan mencampurkan tiga warna dasar: merah (*Red*), hijau (*Green*), dan biru (*Blue*) dalam berbagai intensitas[17]. Setiap warna pada gambar digital direpresentasikan oleh kombinasi dari ketiga komponen ini dengan nilai intensitas yang bervariasi dari 0 hingga 255, menghasilkan sekitar 16 juta warna yang berbeda. Ruang warna RGB memainkan peran penting dalam identifikasi produk pertanian karena banyak produk pertanian yang memiliki ciri khas warna yang dapat diidentifikasi secara visual. Misalnya, dalam klasifikasi kematangan buah atau deteksi penyakit tanaman, perbedaan warna sering kali menunjukkan tahap kematangan atau adanya infeksi. Dengan menggunakan teknik pengolahan citra berbasis RGB, sistem otomatis dapat mengukur intensitas warna dari produk pertanian dan membandingkannya dengan nilai referensi yang telah ditetapkan.

## 2.3. Mean, Variance dan Range

*Mean* atau nilai rata-rata adalah ukuran sentral dari nilai intensitas pada setiap *channel* warna (R, G, B). Nilai *mean* menunjukkan intensitas warna rata-rata dari sebuah gambar dan memberikan informasi tentang tingkat kecerahan umum pada masing-masing *channel*. Persamaan (1) menunjukkan rumus untuk memperoleh nilai *mean*.

$$Mean = \frac{1}{N} \sum_{i=1}^N p_i \quad (1)$$

di mana  $p_i$  adalah nilai intensitas piksel ke- $i$  dan  $N$  adalah jumlah total piksel dalam gambar.

*Variance* mengukur seberapa jauh nilai intensitas dari *mean* pada tiap *channel* warna.

*Variance* memberikan informasi tentang sebaran nilai intensitas dan digunakan untuk memahami variasi warna dalam gambar. Persamaan (2) menunjukkan rumus untuk memperoleh nilai *variance*.

$$Variance = \frac{1}{N} \sum_{i=1}^N (p_i - Mean)^2 \quad (2)$$

*Range* adalah selisih antara nilai intensitas maksimum dan minimum pada tiap *channel* warna. *Range* menunjukkan jangkauan intensitas warna dalam gambar dan membantu mengidentifikasi perbedaan ekstrem dalam nilai intensitas. Persamaan (3) menunjukkan rumus untuk memperoleh nilai *range*.

$$Range = Max(p) - Min(p) \quad (3)$$

di mana  $Max(p)$  adalah nilai intensitas maksimum dan  $Min(p)$  adalah nilai intensitas minimum pada *channel* warna.

## 2.4. SVM Multiclass

Support Vector Machine (SVM) *Multiclass* adalah perluasan dari SVM biner yang digunakan untuk mengklasifikasikan data ke dalam lebih dari dua kelas. SVM *multiclass* ini bekerja dengan membuat beberapa model SVM biner dan menggabungkannya untuk melakukan klasifikasi *multiclass*. Ada dua pendekatan utama untuk SVM *multiclass*: *One-vs-One* (OvO) dan *One-vs-All* (OvA). Fungsi keputusan SVM dinyatakan sebagai:

$$f(x) = w^T x + b \quad (5)$$

di mana  $w$  adalah vektor bobot,  $x$  adalah vektor fitur, dan  $b$  adalah bias. Tujuan SVM adalah menemukan *hyperplane* yang memaksimalkan *margin* antara kelas-kelas. Persamaan 6 menunjukkan fungsi optimasi untuk SVM biner.

$$\min_{w,b} = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \max(0, 1 - y_i(w^T x_i + b)) \quad (6)$$

di mana  $C$  adalah parameter regulasi,  $y_i$  adalah label kelas (-1 atau 1), dan  $x_i$  adalah sampel data.

### 3. METODE PENELITIAN

Gambar 2 menunjukkan tahapan dari metode yang diusulkan dalam penelitian ini. Tahap pertama adalah akuisisi citra cabai merah keriting menggunakan perangkat kamera *smartphone*. Data yang diakuisisi adalah sebanyak 60 citra. Selanjutnya dilakukan tahap pemisahan nilai *red*, *green* dan *blue* dari ruang warna RGB. Tahap selanjutnya adalah perhitungan nilai *mean*, *variance*, dan *range*. Klasifikasi dilakukan dengan SVM *Multiclass* sekaligus uji performa sistem.



Gambar 2. Tahapan Penelitian

#### 3.1. Akuisisi Citra Cabai Merah Keriting

Proses akuisisi citra cabai merah keriting dilakukan dengan menggunakan kamera *smartphone* VIVO 1820. Metode pengambilan gambar dilakukan di luar ruangan dengan menggunakan latar belakang putih untuk memastikan kontras yang baik antara objek dan latar belakang. Setiap citra diambil dari jarak sekitar 15 cm untuk mendapatkan detail yang cukup tanpa distorsi perspektif.

Cabai merah keriting dikelompokkan ke dalam 3 kelas: matang, mentah, dan setengah matang. Untuk setiap kelas, diambil 20 citra sehingga total citra yang diambil adalah sebanyak 60 citra. Setelah pengambilan gambar selesai, citra dibagi menjadi dua kelompok: data latih dan data uji. Dari total 60 citra, 48 citra digunakan sebagai data latih dan 12 citra sebagai data uji. Pembagian ini dilakukan secara merata, dengan masing-masing kelas

memiliki 16 citra untuk data latih dan 4 citra untuk data uji. Gambar 3 merupakan contoh citra cabai yang telah diakuisisi dalam penelitian ini.



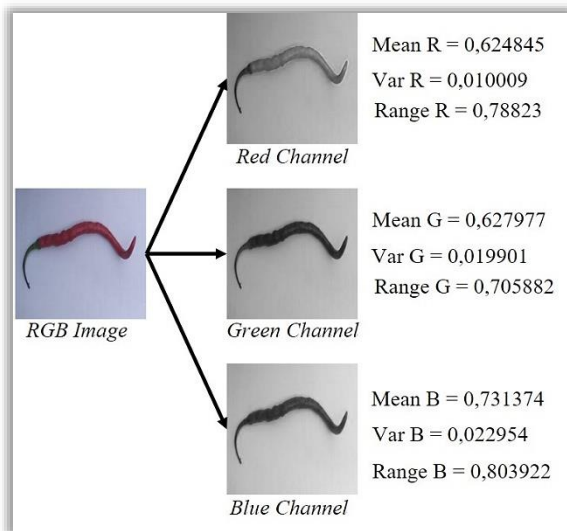
Gambar 3. Contoh citra tiap kelas cabai hasil akuisisi

#### 3.2. Pemisahan Kanal Warna RGB

Citra RGB terdiri dari tiga *channel* warna dasar, yaitu: merah (R), hijau (G), dan biru (B). Setiap *channel* menyimpan informasi intensitas warna masing-masing. Secara teori, citra RGB direpresentasikan sebagai matriks 3D dengan dimensi  $M \times N \times 3$ , di mana  $M$  dan  $N$  adalah jumlah baris dan kolom, serta 3 adalah jumlah *channel*. Untuk memisahkan tiap *channel*, maka dilakukan ekstraksi layer pertama untuk *channel* merah, layer kedua untuk *channel* hijau, dan layer ketiga untuk *channel* biru. Jika terdapat sebuah citra RGB yang diwakili oleh matriks 3D dengan dimensi  $M \times N \times 3$ , maka *Channel* Merah (R) diperoleh dengan  $R = I(:, :, 1)$ , *Channel* Hijau (G):  $G = I(:, :, 2)$ , dan *Channel* Biru  $B = I(:, :, 3)$ .

#### 3.3. Ekstraksi Fitur Mean, Variance dan Range

Untuk mengekstraksi fitur mean, variance, dan range dari citra RGB cabai yang telah diakuisisi dengan kamera, pertama-tama citra dipisahkan menjadi tiga saluran warna: R (merah), G (hijau), dan B (biru). Setiap saluran warna dianalisis secara terpisah. Mean dihitung dengan menggunakan Persamaan (1), variance dihitung dengan menggunakan Persamaan (2), dan range dihitung dengan menggunakan Persamaan (3). Proses ini membantu dalam mengidentifikasi karakteristik warna citra cabai yang berbeda-beda tingkat kematangannya. Gambar 4 menunjukkan contoh proses ekstraksi fitur *mean*, *variance* dan *range* yang dilakukan dalam penelitian ini.



Gambar 4. Ekstraksi fitur

### 3.4. Klasifikasi dengan SVM Multiclass

Setelah ekstraksi fitur *mean*, *variance*, dan *range* dari ruang warna RGB, langkah berikutnya adalah klasifikasi menggunakan SVM Multiclass. SVM Multiclass adalah metode klasifikasi yang mampu memisahkan data ke dalam lebih dari dua kelas. Pada penelitian ini, SVM digunakan untuk mengklasifikasikan citra cabai merah keriting menjadi tiga kelas: matang, mentah, dan setengah matang. SVM Multiclass bekerja dengan membangun beberapa SVM biner, kemudian menggabungkan hasilnya untuk menentukan kelas akhir. Penelitian ini menggunakan kernel linear karena kesederhanaan dan efektivitasnya dalam memisahkan data yang memiliki hubungan linier, serta kemampuannya untuk memberikan hasil klasifikasi yang akurat tanpa memerlukan banyak parameter untuk diatur. Gambar 5 menunjukkan potongan kode untuk proses klasifikasi dengan SVM Multiclass menggunakan tools MATLAB.

```
%membaca seluruh fitur citra latih
training1 = xlsread('fiturlatih');
%label kelas citra latih
group = training1(:,10)
%fitur vektor citra latih
training = [training1(:,1)
training1(:,2) training1(:,3)
training1(:,4) training1(:,5)
training1(:,6) training1(:,7)
training1(:,8) training1(:,9) ]
%fitur vektor citra uji
```

```
Z=[mean_r mean_g mean_b variance_r
variance_g variance_b range_r
range_g range_b ];

% Tentukan kernel SVM
template =
templateSVM('KernelFunction',
'linear');
% Melatih model SVM multiclass
svmModel = fitcecoc(training, group,
'Coding', 'onevsall', 'Learners',
template);
% Memprediksi label data uji
LabelPrediksi = predict(svmModel, Z)

% Inisialisasi kelas
kelas = '';
if LabelPrediksi == 1
    kelas = 'MATANG';
elseif LabelPrediksi == 2
    kelas = 'MENTAH';
elseif LabelPrediksi == 3
    kelas = 'SETENGAH-MATANG';
end
```

Gambar 5. Kode program klasifikasi dengan SVM Multiclass

### 3.5. Pengujian Performansi

Setelah melakukan klasifikasi dengan SVM *multiclass*, performansi model diukur berdasarkan nilai akurasi[4], yang ditunjukkan oleh Persamaan (7).

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total jumlah prediksi}} \times 100\% \quad (7)$$

Untuk validasi model SVM *multiclass*, dilakukan *k-fold cross-validation*, yang tujuannya adalah untuk memastikan model memiliki kemampuan generalisasi yang baik[18]. Dalam *k-fold cross-validation*, data dibagi menjadi *k subset* (atau "*fold*"), dan model dilatih dan diuji sebanyak *k* kali, masing-masing kali menggunakan satu *subset* sebagai data uji dan sisanya sebagai data latih [8], [19]. Proses ini memberikan gambaran yang lebih akurat tentang performansi model di berbagai subset data, mengurangi kemungkinan bias yang dapat terjadi jika hanya satu subset digunakan untuk pengujian

## 4. HASIL DAN PEMBAHASAN

Penelitian ini diimplementasikan menggunakan MATLAB R2015b, mencakup seluruh tahapan mulai dari ekstraksi fitur hingga klasifikasi dengan SVM *Multiclass*. Pengujian dilakukan melalui beberapa skenario yang berbeda untuk mengevaluasi performa



model. Pada skenario pertama, data dibagi dengan persentase 80% untuk data latih dan 20% untuk data uji. Tujuan dari pengujian ini adalah untuk mengevaluasi performa model ketika dilatih dengan sebagian besar data dan diuji dengan sebagian kecil data. Skenario kedua melibatkan *10-fold cross validation*, di mana 60 citra dibagi menjadi 10 subset. Setiap subset digunakan sekali sebagai data uji sementara 9 subset lainnya digunakan sebagai data latih, proses ini diulang sebanyak 10 kali. Tujuan dari skenario pengujian ini adalah untuk mengurangi bias yang mungkin terjadi dan memberikan gambaran yang lebih akurat mengenai performa model. Terakhir, pada skenario ketiga, pengujian dilakukan dengan menggunakan masing-masing fitur (*mean*, *variance*, dan *range*) secara terpisah, serta menggabungkan ketiganya. Tujuan dari skenario pengujian ini adalah untuk mengetahui pengaruh setiap fitur terhadap akurasi klasifikasi.




Gambar 6. Antarmuka sistem klasifikasi yang dibangun

Gambar 6 menunjukkan antarmuka sistem klasifikasi kematangan cabai merah keriting berbasis pengolahan citra digital yang telah dibangun dengan menggunakan MATLAB Guide. Pada bagian kiri terdapat tombol untuk operasi dan *text field* untuk menampilkan hasil klasifikasi. Di bagian tengah terdapat *axes* untuk menampilkan gambar yang dimuat. Sedangkan di bagian kanan merupakan tabel yang menampilkan fitur *mean*, *variance* dan *range* secara otomatis ketika proses klasifikasi dilakukan. Untuk skenario pertama, dengan menggunakan sistem ini, maka data dibagi menjadi 48 data latih dan 12 data uji. Hasil pengujian menunjukkan bahwa akurasi klasifikasi mencapai 100%, yang menunjukkan


kemampuan model SVM Multiclass dengan kernel Linear dalam mengidentifikasi tingkat kematangan cabai merah keriting dengan sangat baik. Tabel 1 menunjukkan hasil klasifikasi pada skenario pengujian ini, di mana perbandingan data latih dan data uji adalah 80:20.

Tabel 1. Hasil Pegujian dengan SVM Multiclass

No	Data Uji	Fitur Vektor <i>Mean, Var, Range</i>	Kelas	Hasil Prediksi
1		0,627 0,644 0,750 0,011 0,014 0,016 0,639 0,714 0,784	Matang	Matang
2		0,631 0,644 0,748 0,009 0,016 0,018 0,698 0,733 0,769	Matang	Matang
3		0,578 0,591 0,697 0,011 0,017 0,019 0,812 0,686 0,800	Matang	Matang
4		0,645 0,656 0,761 0,010 0,016 0,017 0,659 0,749 0,784	Matang	Matang
5		0,699 0,665 0,770 0,018 0,016 0,023 0,812 0,765 0,851	Mentah	Mentah
6		0,719 0,662 0,761 0,018 0,015 0,022 0,776 0,722 0,831	Mentah	Mentah
7		0,685 0,637 0,741 0,021 0,018 0,027 0,784 0,737 0,867	Mentah	Mentah
8		0,640 0,652 0,787 0,015 0,014 0,020 0,773 0,753 0,890	Mentah	Mentah
9		0,600 0,595 0,609 0,020 0,021 0,022 0,820 0,788 0,820	Setengah Matang	Setengah Matang
10		0,623 0,623 0,640 0,020 0,021 0,022 0,902 0,796 0,827	Setengah Matang	Setengah Matang
11		0,630 0,627 0,662 0,018 0,021 0,022 0,788 0,804 0,827	Setengah Matang	Setengah Matang

12		0,659 0,659 0,696 0,023 0,023 0,025 0,812 0,835 0,847	Setengah Matang	Setengah Matang
<b>Akurasi</b>				<b>100%</b>

Dalam skenario kedua, klasifikasi dilakukan menggunakan metode *10-fold cross validation*. Metode ini membagi data menjadi 10 subset (*fold*), di mana setiap subset digunakan sekali sebagai data uji dan 9 subset lainnya digunakan sebagai data latih. Dengan total 60 citra, tiap *fold* akan memiliki 54 data latih dan 6 data uji. Hasil pengujian menunjukkan akurasi sebesar 98,33%. Terdapat satu citra kelas matang yang salah terklasifikasi sebagai kelas setengah-matang. Hal ini ditunjukkan oleh *confusion matrix* yang dapat dilihat pada Gambar 7. *Confusion matrix* adalah tabel yang digunakan untuk menilai kinerja algoritma klasifikasi dengan menunjukkan jumlah prediksi benar dan salah yang dilakukan oleh model untuk setiap kelas.



Gambar 7. *Confusion Matrix* hasil 10-fold cross validation

Gambar 8 menunjukkan citra kelas “matang” yang terklasifikasi sebagai citra kelas “setengah-matang”. Kesalahan klasifikasi ini mungkin disebabkan oleh kemiripan visual antara citra kelas “matang” dan “setengah-matang”. Pencahayaan yang kurang bagus juga bisa mempengaruhi tampilan visual dari cabai sehingga menghasilkan warna yang cenderung sama untuk citra dengan kelas yang berbeda.



Gambar 8. Citra yang mengalami kesalahan klasifikasi

Pada skenario ketiga ini, dilakukan pengujian dengan berbagai kombinasi fitur yang diekstraksi dari citra cabai merah keriting. Pengujian ini bertujuan untuk mengevaluasi pengaruh jumlah dan jenis fitur terhadap akurasi klasifikasi. Tabel 2 menyajikan hasil pengujian ini:

Tabel 2. Hasil Pengujian Jumlah Fitur

Fitur	Panjang Fitur	Akurasi (%)
<i>Mean</i>	1×3	93,33
<i>Variance</i>	1×3	91,67
<i>Range</i>	1×3	96,67
<i>Mean+Variance+Range</i>	1×9	<b>98,33</b>

Dari Tabel 2 tersebut, untuk fitur *Mean* dengan panjang fitur 1×3, akurasi klasifikasi mencapai 93,33%. Fitur mean merepresentasikan nilai rata-rata dari masing-masing *channel* warna (R, G, dan B). Untuk fitur *variance*, juga menggunakan panjang fitur 1×3, akurasi mencapai 91,67% yang lebih rendah hasilnya daripada fitur *mean*. *Variance* mengukur penyebaran nilai piksel dalam setiap *channel* warna. Fitur *Range* menghasilkan akurasi yang lebih tinggi dibandingkan 2 fitur tunggal lainnya, ditunjukkan dengan nilai yaitu 96,67%. *Range* mengukur perbedaan antara nilai piksel maksimum dan minimum dalam setiap *channel* warna. Kemudian, kombinasi semua fitur ini (dengan panjang fitur 1×9) memberikan akurasi terbaik sebesar 98,33%. Kombinasi ini menggabungkan informasi dari intensitas warna rata-rata, penyebaran, dan rentang variasi, sehingga menghasilkan representasi fitur yang lebih komprehensif untuk klasifikasi. Kesimpulannya, penggabungan beberapa jenis fitur menghasilkan peningkatan akurasi yang signifikan, menunjukkan pentingnya menggunakan berbagai jenis informasi dari citra untuk klasifikasi yang lebih akurat.

Hasil pengujian dalam penelitian ini menunjukkan bahwa metode klasifikasi SVM *multiclass* dengan kernel linear dapat secara efektif mengklasifikasikan citra cabai merah keriting berdasarkan tiga kelas kematangan: matang, mentah, dan setengah matang. Pada skenario pertama, penggunaan pembagian data latih dan uji dengan persentase 80:20 menghasilkan akurasi yang tinggi, yang menunjukkan bahwa model ini dapat diandalkan untuk klasifikasi awal. Skenario kedua dengan *10-fold cross validation* memberikan akurasi 98,33%, mengindikasikan model yang konsisten dan stabil. Meski ada satu kesalahan klasifikasi, hasil ini tetap menunjukkan performa yang kuat dari model. Skenario ketiga yang mengevaluasi berbagai kombinasi fitur menunjukkan bahwa kombinasi fitur *mean*, *variance*, dan *range* memberikan akurasi tertinggi. Ini menggarisbawahi pentingnya menggunakan berbagai fitur untuk mendapatkan representasi yang lebih lengkap dari citra dan meningkatkan akurasi klasifikasi. Secara keseluruhan, penelitian ini mengindikasikan potensi besar dari SVM *multiclass* dengan kernel linear untuk klasifikasi otomatis kematangan cabai merah keriting dalam aplikasi pertanian.

## 5. KESIMPULAN

- a. Penelitian menunjukkan bahwa metode SVM *multiclass* dengan kernel linear sangat efektif dalam klasifikasi kematangan cabai merah keriting, dengan tingkat akurasi mencapai 98,33%. Ini menunjukkan potensi metode ini untuk diaplikasikan dalam sistem klasifikasi otomatis di bidang pertanian lainnya.
- b. Penggunaan kombinasi fitur *mean*, *variance*, dan *range* dari ruang warna RGB memberikan hasil klasifikasi yang lebih akurat dibandingkan penggunaan fitur tunggal. Ini menekankan pentingnya penggunaan berbagai fitur untuk representasi citra yang lebih komprehensif dalam analisis citra digital.

## DAFTAR PUSTAKA

- [1] Eni Istiyanti, "Efisiensi Pemasaran Cabai Merah Keriting Di Kecamatan Ngemplak Kabupaten Sleman (The Marketing Efficiency Of Red Chili In Ngemplak Regency Sleman Distric)," *J. Pertan. MAPETA*, vol. XII, no. 2, pp. 116–124, 2015.
- [2] N. T. Anggraeni and A. Fadlil, "Sistem Identifikasi Citra Jenis Cabai (*Capsicum Annum* L.) Menggunakan Metode Klasifikasi City Block Distance," *JSTIE (Jurnal Sarj. Tek. Inform.)*, vol. 1, no. 2, pp. 409–418, 2013.
- [3] M. Muchtar, Y. P. Pasrun, R. Rasyid, N. Miftachurohmah, and M. Mardawati, "PENERAPAN METODE NAÏVE BAYES DALAM KLASIFIKASI KESEGERAN IKAN BERDASARKAN WARNA PADA CITRA AREA MATA," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, Jan. 2024, doi: 10.23960/jitet.v12i1.3879.
- [4] M. Muchtar and R. A. Muchtar, "Integrasi fitur warna, tekstur dan renyi fraktal untuk klasifikasi penyakit daun kentang menggunakan linear discriminant analysis," *J. Mnemon.*, vol. 7, no. 1, pp. 77–84, 2024.
- [5] F. Liantoni and F. N. Annisa, "Fuzzy K-Nearest Neighbor Pada Klasifikasi Kematangan Cabai Berdasarkan Fitur Hsv Citra," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 3, no. 2, pp. 101–108, 2018, doi: 10.29100/jupi.v3i2.851.
- [6] X. Chao, G. Sun, H. Zhao, M. Li, and D. He, "Identification of apple tree leaf diseases based on deep learning models," *Symmetry (Basel)*, vol. 12, no. 7, Jul. 2020, doi: 10.3390/sym12071065.
- [7] M. Muchtar and L. Cahyani, "Klasifikasi Citra Daun dengan Metode Gabor Co-Occurrence," *Ultim. Comput.*, vol. VII, no. 2, pp. 39–47, 2015.
- [8] M. Muchtar and R. A. Muchtar, "Perbandingan Metode KNN dan SVM Dalam Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV dan Fitur Statistik," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 2, pp. 876–884, 2024.
- [9] N. El-Bendary, E. El Hariri, A. E. Hassanien, and A. Badr, "Using machine learning techniques for evaluating tomato ripeness," *Expert Syst. Appl.*, vol. 42, no. 4, pp. 1892–1905, 2015, doi: 10.1016/j.eswa.2014.09.057.
- [10] H. Khotimah, N. Nafi'iyah, and Masrurroh, "Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV dengan KNN," *ELTI J. Elektron. List. dan Teknol. Inf. Terap.*, vol. 2, no. 1, pp. 1–7, Dec. 2019, [Online]. Available: <https://ojs.politeknikjambi.ac.id/elti>
- [11] M. H. Hanafi, N. Fadillah, and A. Insan,



- “Optimasi Algoritma K-Nearest Neighbor untuk Klasifikasi Tingkat Kematangan Buah Alpukat Berdasarkan Warna,” *It J. Res. Dev.*, vol. 4, no. 1, pp. 10–18, 2019, doi: 10.25299/itjrd.2019.vol4(1).2477.
- [12] T. Purwaningsih, I. A. Anjani, and P. B. Utami, “Convolutional Neural Networks Implementation for Chili Classification,” *Proceeding - 2018 Int. Symp. Adv. Intell. Informatics Revolutionize Intell. Informatics Spectr. Humanit. SAIN 2018*, pp. 190–194, 2018, doi: 10.1109/SAIN.2018.8673373.
- [13] J. Pardede, M. G. Husada, A. N. Hermana, and S. A. Rumapea, “Fruit ripeness based on RGB, HSV, HSL, L ab color feature using SVM,” in *2019 International Conference of Computer Science and Information Technology (ICoSNIKOM)*, Nov. 2019, pp. 1–5.
- [14] R. Ali, R. Hardie, and A. Essa, “A Leaf Recognition Approach to Plant Classification Using Machine Learning,” *Proc. IEEE Natl. Aerosp. Electron. Conf. NAECON*, vol. 2018-July, pp. 431–434, 2018, doi: 10.1109/NAECON.2018.8556785.
- [15] V. Soelaiman and A. Ernawati, “Pertumbuhan dan Perkembangan Cabai Keriting (*Capsicum annum* L.) secara In Vitro pada beberapa Konsentrasi BAP dan IAA,” *Bul. Agrohorti*, vol. 1, no. 1, p. 62, 2013, doi: 10.29244/agrob.1.1.62-66.
- [16] K. Science, “*Capsicum annum* L.,” *Plants of the World Online*, 2023. <https://powo.science.kew.org/taxon/urn:lsid:ipni.org:names:316944-2> (accessed May 22, 2024).
- [17] M. Muchtar and R. Riska, “Deteksi Area Kerusakan Pada Citra Terumbu Karang Akibat Coral Bleaching Berbasis Pengolahan Citra Digital,” *J. Innov. Futur. Technol. P-ISSN*, vol. 5, pp. 2656–1719, 2023.
- [18] M. Muchtar, “Penggabungan Fitur Dimensi Fraktal dan Lacunarity untuk Klasifikasi Daun,” Institut Teknologi Sepuluh Nopember, Surabaya, 2015.
- [19] M. Muchtar, N. Suciati, and C. Fatichah, “Fractal Dimension and Lacunarity Combination for Plant Leaf Classification,” *J. Ilmu Komput. dan Inf.*, vol. 9, no. 2, p. 96, Jun. 2016, doi: 10.21609/jiki.v9i2.385.