

# PERBANDINGAN METODE KNN DAN SVM DALAM KLASIFIKASI KEMATANGAN BUAH MANGGA BERDASARKAN CITRA HSV DAN FITUR STATISTIK

Mutmainnah Muchtar<sup>1\*</sup>, Rafiqah Arjaliyah Muchtar<sup>2</sup>

<sup>1</sup>Universitas Sembilanbelas November Kolaka, Sulawesi Tenggara

<sup>2</sup>Universitas Halu Oleo Kendari, Sulawesi Tenggara

## Riwayat artikel:

Received: 16 Januari 2024

Accepted: 30 Maret 2024

Published: 2 April 2024

## Keywords:

3-5 keyword;

HSV;

KNN;

Mango Classification;

SVM.

## Correspondent Email:

[muchtarmutmainnah@gmail.com](mailto:muchtarmutmainnah@gmail.com)

**Abstrak.** Penelitian ini membahas perbandingan metode klasifikasi *K-Nearest Neighbors* (KNN) dan *Support Vector Machine* (SVM) dalam mengidentifikasi tingkat kematangan buah mangga berdasarkan citra HSV dan fitur statistik. Sebanyak 80 citra buah mangga dibagi menjadi dua kelas, yaitu kelas mangga "matang" dan "belum matang," dengan masing-masing 40 citra. Pengujian dilakukan menggunakan *k-cross validation*, dan hasil menunjukkan bahwa KNN mencapai akurasi 98,75%, sedangkan SVM mencapai 97,5%. Metode KNN memperoleh performa lebih unggul dan konsisten, memberikan keyakinan bahwa pendekatan tersebut efektif untuk klasifikasi tingkat kematangan buah mangga. Penelitian ini dapat memberikan kontribusi pada pengembangan sistem otomatisasi pengolahan buah mangga yang memanfaatkan teknologi citra dan pembelajaran mesin untuk mendukung industri pertanian dan pangan.

**Abstract.** This research compares the classification methods of *K-Nearest Neighbors* (KNN) and *Support Vector Machine* (SVM) in identifying the ripeness level of mango fruit based on HSV images and statistical features. A total of 80 mango fruit images were categorized into two classes, namely "ripe" and "unripe" mango, with 40 images each. Testing was conducted using *k-cross validation*, revealing that KNN achieved an accuracy of 98.75%, while SVM reached 97.5%. KNN demonstrated superior and consistent performance, indicating its effectiveness in mango fruit ripeness classification. The study contributes to the advancement of automated systems for mango fruit processing, leveraging image technology and machine learning to support the agriculture and food industry.

## 1. PENDAHULUAN

Mangga merupakan buah tropis yang sangat dicari di pasar dalam maupun luar negeri, di mana tingkat kematangannya memiliki dampak signifikan terhadap nilai dan kualitasnya[1], [2]. Dalam upaya untuk meningkatkan efisiensi dan ketepatan penilaian kematangan mangga, metode otomatis menjadi semakin penting[3].

Penelitian sebelumnya telah mengeksplorasi berbagai teknik untuk menilai kematangan buah, dengan penekanan khusus pada visi komputer dan pembelajaran mesin. Penelitian oleh [1] mengklasifikasikan kematangan buah mangga berdasarkan citra HSV dengan metode KNN (*K-Nearest Neighbors*) untuk 4 kelas citra mangga, diperoleh akurasi sebesar 80%.

Kemudian, [2] juga menerapkan metode KNN dalam mengklasifikasi kematangan buah mangga manalagi menggunakan ruang warna LAB dan fitur statistik. Sedangkan penelitian oleh [3] menggunakan teknik *hybrid* yaitu berdasarkan ruang warna HSV dan berdasarkan bau/aroma dari buah mangga, yang kemudian diklasifikasikan menggunakan metode SVM (*Support Vector Machine*). Hasil pengujian menggunakan 228 citra mangga menunjukkan akurasi hingga 94,69%. Selanjutnya, perbandingan metode KNN dan SVM dilakukan oleh [4] untuk klasifikasi jenis buah pisang berdasarkan fitur warna, tekstur dan bentuk, dimana hasil akurasi metode KNN sedikit lebih unggul dibandingkan SVM.

Pendekatan berbasis citra, terutama yang memanfaatkan ruang warna *Hue-Saturation-Value* (HSV) dan fitur statistik seperti *mean*, standar deviasi, dan *entropy*, telah menunjukkan potensi untuk menangkap karakteristik kematangan dengan lebih rinci. Ruang warna HSV dipilih karena mampu memisahkan informasi warna dan kecerahan dengan lebih baik dibandingkan dengan ruang warna RGB[5]. Hal ini memungkinkan ekstraksi fitur yang lebih akurat dalam menangkap variasi warna yang signifikan pada buah mangga dalam berbagai tingkat kematangan. Keberhasilan HSV dalam memisahkan atribut warna membuat model warna ini menjadi pilihan yang tepat untuk menangani kompleksitas citra buah mangga.

Meskipun penelitian-penelitian tersebut telah memberikan hasil yang cukup jelas, analisis perbandingan antara KNN dan SVM untuk klasifikasi kematangan mangga, yang mencakup baik ruang warna HSV maupun fitur statistik tersebut, masih terbatas. Oleh karena itu, penelitian ini dilakukan dalam rangka mengisi kesenjangan ini, menghadirkan evaluasi terhadap kedua metode tersebut.

Penelitian ini bertujuan untuk membandingkan performansi dari dua metode klasifikasi: *K-Nearest Neighbors* (KNN) dan *Support Vector Machine* (SVM) [4], [6], [7]. Utamanya dalam mengklasifikasikan tingkat kematangan mangga berdasarkan citra HSV dan fitur statistik (*mean*, standar deviasi, *entropy*). Dengan menggunakan teknik validasi silang *k-cross validation*, penelitian ini akan menilai performansi dan keandalan masing-masing metode. Kontribusi ini diharapkan dapat

mendorong pengembangan sistem otomatis untuk penilaian kualitas buah di industri pertanian dan pangan.

## 2. TINJAUAN PUSTAKA

### 2.1. *K-Nearest Neighbor*

*K-Nearest Neighbors* (KNN)[1] adalah algoritma klasifikasi yang beroperasi berdasarkan konsep bahwa objek-objek dengan fitur serupa cenderung berada dalam kelompok atau kelas yang sama. Dalam KNN, setiap objek direpresentasikan dalam ruang fitur multidimensi, dan klasifikasi suatu objek bergantung pada mayoritas label dari  $k$  objek tetangga terdekatnya dalam ruang fitur tersebut. Jika sebagian besar tetangga dari suatu objek termasuk dalam suatu kelas tertentu, maka objek tersebut diklasifikasikan ke dalam kelas tersebut.

*Euclidean Distance* [7], sebagai metode perhitungan jarak yang umum digunakan dalam KNN, mengukur jarak antara dua titik dalam ruang fitur dengan menggunakan formula *Euclidean*. Misalnya, dalam ruang dua dimensi, *Euclidean distance* antara dua titik  $P=(p_1, p_2)$  dan  $Q=(q_1, q_2)$  dihitung sebagai akar dari  $(p_1 - q_1)^2 + (p_2 - q_2)^2$ . Dengan menggunakan *Euclidean distance*, KNN menentukan tetangga terdekat berdasarkan kedekatan spasial antara *data points*, yang memberikan bobot lebih besar kepada *data points* yang secara geometris lebih mirip dengan *data point* yang akan diklasifikasikan. Metode *K-Nearest Neighbors* (KNN) memiliki keunggulan dalam kemudahan implementasi dan interpretasi, serta fleksibilitasnya dalam menangani data non-linear atau non-parametrik.

### 2.2. *Support Vector Machine*

Sebagai algoritma klasifikasi, SVM berusaha untuk menemukan *hyperplane* terbaik yang memisahkan dua kelas dengan memaksimalkan jarak (*margin*) antara kedua kelas. Dua kelas ini ditempatkan pada kedua sisi *hyperplane*, dan *data points* yang mendefinisikan batas keputusan disebut sebagai *support vectors*. SVM dapat bekerja baik dalam ruang fitur berdimensi tinggi dan memiliki fleksibilitas untuk menangani data yang tidak linear dengan menggunakan fungsi kernel untuk mentransformasi data ke dimensi yang lebih tinggi.[6], [8].

Keunggulan SVM termasuk kemampuannya untuk mengatasi masalah *overfitting* karena fokus pada batas keputusan yang umum dan memaksimalkan margin, sehingga mengurangi risiko kesalahan klasifikasi pada data baru. Persamaan matematis SVM tidak dapat dijelaskan secara ringkas tanpa memperkenalkan konsep matematika lanjutan. Secara umum, untuk klasifikasi biner, persamaan *hyperplane* pada SVM dapat diwakili sebagai:

$$f(x) = \text{sign}(w \cdot x + b) \quad (2)$$

dimana:

$f(x)$  = fungsi keputusan

$w$  = vektor bobot

$x$  = fitur vektor data input

$b$  = konstanta bias

$\cdot$  = operasi *dot product*

*sign* = fungsi tanda

### 2.3. Ruang Warna HSV

Ruang warna HSV (*Hue, Saturation, Value*) merupakan model warna yang menggambarkan warna sebagai kombinasi dari tiga komponen utama: *Hue* (warna), *Saturation* (kejenuhan), dan *Value* (nilai kecerahan). Keunggulan utama ruang warna HSV dibandingkan dengan ruang warna RGB (*Red, Green, Blue*) adalah kemampuannya untuk memisahkan informasi warna, kejenuhan, dan kecerahan dengan lebih baik. Persamaan (2-6) menunjukkan rumus untuk mengkonversi citra RGB ke citra HSV [5], [9].

$$V = \max(R, G, B) \quad (2)$$

$$S = V - \min(R, G, B)/V \quad (3)$$

$$H = \frac{G-B}{6S}, \text{ jika } V = R \quad (4)$$

$$H = \frac{1}{3} + \frac{B-R}{6S}, \text{ jika } V = G \quad (5)$$

$$H = \frac{2}{3} + \frac{R-G}{6S}, \text{ jika } V = B \quad (6)$$

### 2.4. Fitur Statistik

Fitur statistik dalam klasifikasi citra merujuk pada ekstraksi informasi numerik yang menggambarkan sifat statistik distribusi intensitas piksel pada suatu citra. Fitur-fitur statistik ini memberikan representasi numerik tentang variasi, sebaran, dan distribusi kecerahan piksel di dalam citra, yang dapat digunakan untuk tujuan klasifikasi atau pengenalan pola.

Contoh fitur statistik yang umum digunakan termasuk *mean* (rata-rata), standar deviasi, dan *entropy*[2], [10]. *Mean* digunakan untuk menunjukkan tingkat kecerahan umum di dalam citra. Standar deviasi digunakan untuk mengukur sejauh mana intensitas piksel tersebar dari nilai rata-rata, sedangkan *entropy* untuk mengukur tingkat ketidakpastian atau kompleksitas distribusi intensitas piksel. Persamaan (7-9) menunjukkan rumus untuk memperoleh nilai *mean*, standar deviasi, dan *entropy*.

$$\text{Mean} = \frac{1}{N} \sum_{i=1}^N X_i \quad (7)$$


$$\text{Standar deviasi} = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \text{Mean})^2} \quad (8)$$

$$\text{Entropy} = - \sum_{i=1}^L p(i) \cdot \log_2(p(i)) \quad (9)$$

dimana  $N$  adalah jumlah piksel dalam citra dan  $X_i$  adalah nilai intensitas piksel ke- $i$ .  $L$  adalah jumlah tingkat intensitas sedangkan  $p(i)$  adalah probabilitas munculnya tingkat intensitas ke- $i$ .

## 3. METODE PENELITIAN

Penelitian ini terdiri dari beberapa tahapan. Gambar 1 menunjukkan tahapan dari metode yang diusulkan. Tahap pertama adalah pengumpulan data citra buah mangga. Total data yang digunakan berjumlah 80 citra buah mangga. Selanjutnya dilakukan konversi dari ruang warna RGB ke HSV. Berdasarkan nilai HSV ini, maka citra mangga kemudian disegmentasi sehingga menghasilkan citra biner. Tahap selanjutnya adalah ekstraksi fitur statistik dan klasifikasi dengan KNN dan SVM sekaligus analisis performa.



Gambar 1. Metode Penelitian

### 3.1. Pengumpulan Data

Sebanyak 80 citra buah mangga utuh diperoleh secara daring dari situs *kaggle.com*. Data terdiri atas 2 kelas. Kelas mangga “matang” terdiri atas 40 citra dan kelas mangga “belum matang” terdiri atas 40 citra. Dimensi tiap citra adalah 800x800 piksel dengan tipe data JPG. Gambar 2 dan 3 menunjukkan citra buah mangga yang termasuk ke dalam 2 kelas yang dimaksud.



Gambar 2. Data 40 citra kelas “matang”



Gambar 3. Data 40 citra kelas “belum matang”

### 3.2. Segmentasi Warna HSV

Segmentasi citra adalah proses pembagian citra menjadi *region* yang lebih kecil berdasarkan ciri tertentu [11], [12], [13]. Langkah pertama dalam segmentasi citra berdasarkan ruang warna HSV adalah mengkonversi citra dari ruang warna RGB ke ruang warna HSV. Setelah itu, kita dapat menentukan batas nilai *Hue*, *Saturation*, dan *Value* yang sesuai dengan objek yang ingin di-segmentasi.

Proses segmentasi selanjutnya melibatkan penerapan filter atau operasi *thresholding* untuk mengidentifikasi bagian-bagian citra yang memenuhi kriteria warna yang telah ditentukan. Hasilnya adalah citra biner di mana objek yang diinginkan terisolasi dengan latar belakang yang terhapus. Mensegmentasi citra berdasarkan ruang warna HSV memungkinkan kita untuk lebih fokus pada informasi warna yang spesifik, meningkatkan akurasi dan ketepatan dalam mengidentifikasi objek atau wilayah yang diinginkan dalam citra. Adapun

aturan atau *rule* untuk menentukan batas atas (*ba*) dan batas bawah (*bb*) dari citra berwarna hijau muda yang mirip dengan warna mangga yang belum matang, adalah:

$$bb = H = 0.25, S = 0.3, V = 0.5 \quad (10)$$

$$ba = H = 0.45, S = 1.0, V = 1.0 \quad (11)$$


Selanjutnya dilakukan segmentasi dengan persamaan berikut:

$$(H \geq bb[1]) \ \& \ (H \leq ba[1]) \quad (12)$$

$$(S \geq bb[2]) \ \& \ (S \leq ba[2]) \quad (13)$$

$$(V \geq bb[3]) \ \& \ (V \leq ba[3]) \quad (14)$$

dimana [1], [2], dan [3] merujuk pada indeks atau komponen tertentu dari vektor atau *array*. Dalam kasus ini, vektor tersebut adalah vektor yang menyatakan nilai-nilai *Hue* (H), *Saturation* (S), dan *Value* (V) dalam model warna HSV. Sedangkan *bb* dan *ba* merupakan batas bawah dan batas atas dari masing-masing nilai H, S, dan V untuk proses segmentasi. Dengan menggunakan *rule* ini, citra mangga yang belum matang akan disegmentasi dengan jelas, karena memiliki warna hijau muda yang dominan. Sedangkan untuk mangga yang matang, maka jumlah warna hijau muda yang tersegmentasi adalah sangat minim. Gambar 4 merupakan contoh hasil penerapan segmentasi menggunakan aturan yang diajukan dalam penelitian ini.



Gambar 4. Citra input (kiri) dan citra hasil segmentasi (kanan)

### 3.3. Perhitungan Fitur Statistik

Untuk memperoleh fitur statistik yang terdiri atas *mean*, standar deviasi dan entropi, maka digunakan persamaan (7-9). Jika segmentasi berhasil memisahkan bagian citra yang sesuai

dengan aturan untuk mangga yang belum matang, citra biner tersebut akan memiliki nilai *mean*, standar deviasi, dan entropi yang mencerminkan karakteristik dari bagian tersebut. Citra mangga untuk kelas “matang” ditandai dengan nilai *mean*, standar deviasi dan entropi yang rendah karena kurangnya nilai piksel berwarna hijau muda pada citra tersebut. Sebaliknya untuk citra mangga kelas “belum matang” ditunjukkan dengan nilai fitur yang tinggi karena adanya area berwarna hijau muda yang dominan. Hasil dari tahap ini menghasilkan 1 vektor fitur yang berisi 3 nilai fitur statistik untuk tiap citra input. Proses ini diterapkan pada seluruh data citra, sehingga dihasilkan matriks berukuran 80x3.

### 3.4. Klasifikasi dengan Metode KNN dan SVM serta Perhitungan Performansi

Klasifikasi dalam pengolahan citra digital adalah proses identifikasi dan penentuan suatu kategori tertentu pada citra, di mana model atau algoritma diprogram untuk mengenali pola visual dan mengatributkannya ke kelas yang telah ditentukan sebelumnya [14]. Setelah berhasil mengekstraksi fitur dari seluruh 80 citra buah mangga dengan kelas “matang” dan “belum matang”, langkah selanjutnya adalah menerapkan metode *K-Nearest Neighbors* (KNN) dan *Support Vector Machine* (SVM) untuk tujuan klasifikasi.

Pertama-tama, data perlu dipisahkan menjadi dua kelompok, yaitu data pelatihan untuk melatih model dan data pengujian untuk menguji kinerja model. Pada metode KNN, penting untuk menentukan parameter *k*, yang merupakan jumlah tetangga terdekat yang akan diperhitungkan dalam proses klasifikasi. Pemilihan *k* yang optimal dapat dilakukan melalui eksperimen dengan beberapa nilai *k* dan evaluasi performa model. Setelah itu, model KNN dapat dilatih menggunakan data pelatihan, dan kemudian digunakan untuk mengklasifikasikan data pengujian. Sementara itu, pada metode SVM, perlu ditentukan jenis kernel yang akan digunakan, seperti kernel linier, polinomial, atau *radial basis function* (RBF). Setelah menentukan parameter, model SVM dilatih dengan data pelatihan dan digunakan untuk mengklasifikasikan data pengujian.

### 3.5. Perhitungan Performansi

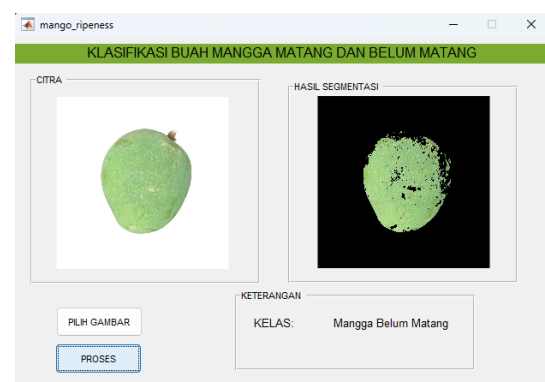
Evaluasi model klasifikasi menjadi langkah selanjutnya dalam penelitian ini untuk membandingkan metode mana yang lebih baik dari segi performa. Metrik evaluasi seperti akurasi, presisi, dan *recall*, dapat digunakan untuk mengevaluasi performa model terhadap data pengujian. Validasi silang atau *k-cross validation* [14] juga dapat diterapkan untuk memastikan generalisasi yang baik terhadap data yang tidak terlihat sebelumnya. Gambar 5 menunjukkan ilustrasi dari *5-fold cross validation* yang digunakan dalam penelitian ini.



Gambar 5. Ilustrasi 5-fold cross validation

## 4. HASIL DAN PEMBAHASAN

Sistem dibangun dengan menggunakan 2 jenis *software/tools*. Proses konversi RGB ke HSV, segmentasi citra dan ekstraksi fitur statistik dilakukan dengan menggunakan *software* Matlab[14]. Sementara itu, proses perbandingan performansi dari metode KNN dan SVM dilakukan dengan menggunakan *software* RapidMiner Studio[15]. Gambar 6 menunjukkan proses segmentasi citra mangga untuk kelas “Belum Matang” dengan menggunakan *software* Matlab berbasis GUI. Sistem terdiri atas 2 tombol yaitu tombol untuk memilih citra mangga dan tombol untuk memproses citra.






Gambar 6. Antarmuka sistem di Matlab

Tabel 1 merupakan hasil ekstraksi fitur statistik yang diperoleh dengan menerapkan rumus perhitungan *mean*, standar deviasi dan entropi pada 80 citra mangga yang telah dikumpulkan. Terlihat bahwa citra mangga kelas “belum matang” menunjukkan nilai *mean*, standar deviasi dan entropi yang lebih tinggi dibandingkan citra mangga kelas “matang”.

Tabel 1. Fitur statistik citra hasil segmentasi

DATA	MEAN	STDEV	ENTR	KELAS
Data1	0,1090	0,3116	0,4969	belum matang
Data2	0,1546	0,3615	0,6211	belum matang
Data3	0,0817	0,2739	0,4082	belum matang
Data4	0,0910	0,2876	0,4397	belum matang
Data5	0,0566	0,2311	0,3138	belum matang
Data6	0,0594	0,2364	0,3252	belum matang
Data7	0,1051	0,3066	0,4849	belum matang
Data8	0,0560	0,2300	0,3115	belum matang
Data9	0,0645	0,2457	0,3451	belum matang
...	...	...	...	...
Data40	0,1291	0,3353	0,5549	belum matang
Data41	0,0000	0,0028	0,0001	matang
Data42	0,0002	0,0150	0,0031	matang
Data43	0,0093	0,0961	0,0762	matang
Data44	0,0000	0,0000	0,0000	matang
Data45	0,0000	0,0000	0,0000	matang
Data46	0,0003	0,0185	0,0044	matang
Data47	0,0056	0,0745	0,0498	matang
Data48	0,0000	0,0000	0,0000	matang
Data49	0,0000	0,0000	0,0000	matang
...	...	...	...	...
Data80	0,0000	0,0000	0,0000	matang

Setelah memperoleh fitur statistik, selanjutnya data diproses dengan menggunakan RapidMiner, untuk dilakukan klasifikasi dengan metode KNN dan SVM. Pada tahap ini juga dilakukan *5-cross validation* dan perhitungan performansi. Karena terdapat 80 citra, maka tiap *fold*-nya terdiri atas 64 data latih dan 16 data uji, dengan jumlah masing-masing data tiap kelas adalah sama. Gambar 7 menunjukkan model pengujian dengan RapidMiner untuk penelitian ini.



Gambar 7. Desain pengujian di RapidMiner

Tabel 2. Perhitungan performansi metode KNN dan SVM

Metode	accuracy (%)	recall (%)	precision (%)
KNN	<b>98,75</b>	<b>97,50</b>	<b>100</b>
SVM	97,50	<b>97,50</b>	97,78

Tabel 2 menunjukkan perbandingan performa dari metode KNN dan SVM dalam klasifikasi citra mangga. Terlihat bahwa dari segi akurasi dan *precision*, metode KNN dengan nilai  $k = 5$  lebih unggul dibandingkan SVM. Sedangkan dari segi *recall*, metode KNN dan SVM memiliki nilai yang sama. Gambar 8 dan 9 menunjukkan *confusion matrix* dari performa metode KNN dan SVM. Terlihat bahwa metode KNN mengalami kesalahan klasifikasi pada 1 citra yang seharusnya termasuk ke dalam kelas “matang”, namun diklasifikasikan sebagai “belum matang”, yaitu pada data citra ke 71. Sehingga akurasi menjadi 98,75%. Sedangkan untuk metode SVM, pada pengujian ini menggunakan kernel linear, mengalami kesalahan klasifikasi pada 2 citra, yaitu data citra ke 23 yang seharusnya “belum matang” namun diklasifikasikan sebagai “matang”, dan data citra ke 71 yang seharusnya “matang” namun diklasifikasikan sebagai “belum matang”. Sehingga akurasi menjadi 97,5%

PerformanceVector	
PerformanceVector:	
accuracy: 98.75% +/- 2.80% (micro average: 98.75%)	
ConfusionMatrix:	
True: belum matang matang	
belum matang: 40	1
matang: 0	39
precision: 100.00% +/- 0.00% (micro average: 100.00%) (positive class: matang)	
ConfusionMatrix:	
True: belum matang matang	
belum matang: 40	1
matang: 0	39
recall: 97.50% +/- 5.59% (micro average: 97.50%) (positive class: matang)	
ConfusionMatrix:	
True: belum matang matang	
belum matang: 40	1
matang: 0	39

Gambar 8. Confusion Matrix metode KNN

**PerformanceVector**

```





PerformanceVector:
accuracy: 97.50% +/- 3.42% (micro average: 97.50%)
ConfusionMatrix:
True:  belum matang  matang
belum matang:  39      1
matang: 1      39
precision: 97.78% +/- 4.97% (micro average: 97.50%) (positive class: matang)
ConfusionMatrix:
True:  belum matang  matang
belum matang:  39      1
matang: 1      39
recall: 97.50% +/- 5.59% (micro average: 97.50%) (positive class: matang)
ConfusionMatrix:
True:  belum matang  matang
belum matang:  39      1
matang: 1      39

```

Gambar 9. *Confusion Matrix* metode SVM

Tabel 3 menunjukkan 2 data citra yang mengalami misklasifikasi dalam penelitian ini, yaitu citra ke 71 dan 23. Pada tabel terlihat bahwa hasil segmentasi pada citra ke 71 menunjukkan komposisi warna hijau muda yang dominan, sehingga yang seharusnya kelas “matang” terklasifikasi menjadi kelas “belum matang”. Sama halnya dengan citra ke 23, yang meskipun memiliki warna hijau muda pada hasil segmentasinya, namun fitur nya masih belum memenuhi kriteria minimum untuk masuk ke dalam kelas “belum matang”. Olehnya itu maka diklasifikasi sebagai “matang”

Tabel 3. Citra yang mengalami kesalahan klasifikasi

Data	segmen tasi	mean, stdev, entropy	kelas	hasil klasifikasi
 citra 71		0,0596 0,2368 0,3259	matang	belum matang
 citra 23		0,0508 0,2196 0,2899	belum matang	matang

Tabel 4. Hasil pengujian parameter  $k$  pada KNN

Nilai $k$	accuracy (%)	recall (%)	precision (%)
3	98,75	97,50	100
5	98,75	97,50	100
7	98,75	97,50	100
9	98,75	97,50	100

Selain itu, dilakukan juga pengujian parameter yang ada pada model KNN dan SVM. Pada metode KNN, parameter yang bisa diubah adalah nilai  $k$  atau jumlah ketetanggaan

terdekat. Oleh karena itu, dilakukan pengujian dengan menggunakan nilai  $k = 3, 5, 7$ , dan  $9$ . Sedangkan pada metode SVM, parameter yang bisa diubah adalah jenis kernelnya. Untuk pengujian kali ini maka digunakan kernel linear, RBF (*Radial Basis Function*), dan *polynomial*.

Tabel 5. Hasil pengujian jenis kernel SVM

Kernel	accuracy (%)	recall (%)	precision (%)
<i>linear</i>	97,50	<b>97,50</b>	97,78
<i>RBF (Radial Basis Function)</i>	<b>98,75</b>	<b>97,50</b>	<b>100</b>
<i>polynomial</i>	75,00	80,00	73,27

Tabel 4 merupakan hasil perbandingan performansi dari metode KNN dengan berbagai nilai  $k$ . Terlihat bahwa, tidak ada perubahan yang signifikan dari performa model yang dimaksud, di mana diperoleh akurasi 97,85%, *precision* 100% dan *recall* 97,50%. Pada pengujian ini, terdapat 1 citra yang mengalami kesalahan klasifikasi dari total keseluruhan data. Sementara itu, Tabel 5 merupakan hasil perbandingan performansi dari metode SVM dengan menggunakan beberapa jenis kernel. Terlihat bahwa akurasi dan *precision* tertinggi yaitu 98,75% dan 100% ditemukan pada kernel RBF. Kemudian didapatkan nilai *recall* yang sama antara kernel linear dan kernel RBF. Sedangkan performa untuk kernel *polynomial* menunjukkan nilai paling rendah pada tiga metrik pengukuran performansi tersebut dibandingkan kernel linear dan RBF.

Meskipun performa keseluruhan adalah baik untuk KNN dan SVM, penting untuk memahami dan mengevaluasi kesalahan klasifikasi untuk meningkatkan keandalan model. Rekomendasi lebih lanjut dapat dilakukan berdasarkan analisis kesalahan klasifikasi dan evaluasi model melalui penyetulan parameter atau penambahan fitur untuk meningkatkan performa model.

## 5. KESIMPULAN

- Metode *K-Nearest Neighbors* (KNN) dengan berbagai nilai  $k$  telah diuji, dan hasilnya menunjukkan bahwa performa model relatif stabil terhadap perubahan nilai  $k$ . Untuk nilai  $k$  *default* yaitu  $k=5$ , diperoleh akurasi sebesar 97,85%,

*precision* 100%, dan *recall* 97,50%. Performa ini menunjukkan tingkat ketepatan dan kecocokan model yang tinggi dalam mengklasifikasikan tingkat kematangan buah mangga.

- b. Metode *Support Vector Machine* (SVM) dengan kernel default yaitu linear menghasilkan akurasi dan *recall* sebesar 97,50% dan *precision* sebesar 97,78%, menunjukkan kemampuan SVM yang baik dalam menangani pemisahan antar kelas pada data buah mangga.

### UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

### DAFTAR PUSTAKA

- [1] H. Khotimah, N. Nafi'iyah, And Masruroh, "Klasifikasi Kematangan Buah Mangga Berdasarkan Citra Hsv Dengan Knn," *Elti Jurnal Elektronika, Listrik Dan Teknologi Informasi Terapan*, Vol. 2, No. 1, Pp. 1–7, Dec. 2019, [Online]. Available: <https://ojs.politeknikjambi.ac.id/elti>
- [2] A. Patriot, S. Pamungkas, N. Nafi'iyah, And N. Q. Nawafilah, "K-Nn Klasifikasi Kematangan Buah Mangga Manalagi Menggunakan L\*A\*B Dan Fitur Statistik," *Jurnal Ilmu Komputer Dan Desain Komunikasi Visual*, Vol. 4, No. 1, 2019.
- [3] M. F. Mavi, Z. Husin, R. Badlishah Ahmad, Y. M. Yacob, R. S. M. Farook, And W. K. Tan, "Mango Ripeness Classification System Using Hybrid Technique," *Indonesian Journal Of Electrical Engineering And Computer Science*, Vol. 14, No. 2, Pp. 859–868, May 2019, Doi: 10.11591/Ijeecs.V14.I2.Pp859-868.
- [4] Y. E. Yana And N. Nafi'iyah, "Classification Of Banana Types Based On Color, Texture, Image Shape Features Using Svm And Knn," *Research : Journal Of Computer, Information System & Technology Management*, Vol. 4, No. 1, Pp. 28–36, 2021.
- [5] 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)*, Ieee, Nov. 2019, Pp. 1–5.
- [6] M. Muchtar, N. Suciati, And C. Fatichah, "Fractal Dimension And Lacunarity Combination For Plant Leaf Classification," *Jurnal Ilmu Komputer Dan Informasi*, Vol. 9, No. 2, P. 96, Jun. 2016, Doi: 10.21609/Jiki.V9i2.385.
- [7] Hasmawati, M. Muchtar, And J. Nangi, "Aplikasi Prediksi Penjualan Barang Menggunakan Metode K-Nearest Neighbor (Knn) (Studi Kasus Tumaka Mart)," *Semantik*, Vol. 3, No. 2, Pp. 151–160, 2017.
- [8] M. Muchtar, "Penggabungan Fitur Dimensi Fraktal Dan Lacunarity Untuk Klasifikasi Daun," Institut Teknologi Sepuluh Nopember, Surabaya, 2015.
- [9] A. Ajmal, C. Hollitt, M. Freen, And H. Al-Sahaf, "A Comparison Of Rgb And Hsv Colour Spaces For Visual Attention Models," In *2018 International Conference On Image And Vision Computing New Zealand (Ivcnz)*, Ieee, 2018, Pp. 1–6.
- [10] M. Sipan And R. K. Pramuyanti, "Analisis Citra Kuning Telur Berbasis Ekstraksi Ciri Statistika Orde Satu Untuk Mengenali Jenis Telur Ayam Ras Dan Ayam Kampung," *Elektrika*, Vol. 13, No. 2, Pp. 74–78, Nov. 2021.
- [11] Y. P. Pasrun, M. Muchtar, A. N. Basyarah, And Noorhasanah, "Indonesian License Plate Detection Using Morphological Operation," In *Iop Conference Series: Materials Science And Engineering*, Institute Of Physics Publishing, Jun. 2020. Doi: 10.1088/1757-899x/797/1/012037.
- [12] M. Muchtar, "Deteksi Area Kerusakan Pada Citra Terumbu Karang Akibat Coral Bleaching Berbasis Pengolahan Citra Digital," *Jurnal Innovation And Future Technology (Iftech) P-Issn*, Vol. 5, Pp. 2656–1719, 2023.
- [13] A. Setiyorini, I. P. N. Purnama, J. Y. Sari, M. Muchtar, And E. Ngii, "Vehicle Number Plate Identification Using Template Matching Algorithm For Automatic Parking System," In *Acm International Conference Proceeding Series*, Association For Computing Machinery, Apr. 2019, Pp. 196–200. Doi: 10.1145/3330482.3330483.
- [14] M. Muchtar, Y. P. Pasrun, R. Rasyid, N. Miftachurohmah, And M. Mardawati, "Penerapan Metode Naïve Bayes Dalam Klasifikasi Kesegaran Ikan Berdasarkan Warna Pada Citra Area Mata," *Jurnal Informatika Dan Teknik Elektro Terapan*, Vol. 12, No. 1, Jan. 2024, Doi: 10.23960/Jitet.V12i1.3879.
- [15] R. Maulidiah, M. Muchtar, N. Aisyah Fitri, I. Asriani, M. Putri Yasmine, And P. Studi, "Pengelompokan Data Pertumbuhan Dan Kontribusi Ekonomi Indonesia Menurut Provinsi Menggunakan Metode K-Means



Clustering,” *Jurnal Teknologi Sistem Informasi Dan Sistem Komputer Tgd*, Vol. 6, No. 2, Pp. 436–444, Jul. 2023, [Online]. Available:  
<https://Ojs.Trigunadharma.Ac.Id/Index.Php/Jsk/Index>