

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Mangga**

Buah mangga (*Mangifera indica*) adalah buah tropis yang sangat populer karena cita rasanya yang manis, segar, dan aromatik. Mangga tumbuh subur di daerah beriklim tropis dan subtropis dengan suhu hangat dan curah hujan sedang. Tanah harus memiliki drainase yang baik dan kaya bahan organik. Praktik budidaya yang umum dilakukan meliputi pencangkakan untuk memastikan jenis tanaman benar, pemangkasan teratur untuk mempertahankan ukuran dan bentuk pohon, serta pengelolaan hama dan penyakit untuk melindungi tanaman. Irigasi sangat penting selama tahap pembungaan dan pematangan untuk memastikan perkembangan buah yang berair dan beraroma (Budiman and Tjandrasa, 2017).

Mangga sangat berperan penting dalam perekonomian banyak negara tropis dan subtropis. Mereka adalah produk ekspor utama bagi negara-negara seperti India, Thailand, Meksiko, dan Filipina. Permintaan mangga global terus meningkat karena popularitas dan manfaat nutrisinya. Industri mangga menyediakan lapangan kerja bagi jutaan petani, buruh, dan pekerja yang terlibat dalam budidaya, pengolahan, dan distribusi. Selain itu, mangga berkontribusi pada industri pengolahan makanan, digunakan dalam produk seperti jus, buah kering, dan makanan kaleng. Mangga memiliki berbagai varietas dengan beragam bentuk, ukuran, dan warna kulit yang mencakup kuning, hijau, merah, atau oranye. Kulitnya bisa halus atau kasar tergantung pada jenisnya. Buah ini memiliki daging tebal,

lembut, dan sangat berair, yang dapat bervariasi dari kuning pucat hingga oranye cerah, tergantung pada varietasnya. Mangga diminati pasar internasional serta mempunyai harga jual di tingkat petani yang tinggi dibandingkan dengan varietas mangga lainnya (Pedekawati, Karyani and Sulistyowati, 2017). Mangga dikenal sebagai sumber nutrisi yang kaya, mengandung vitamin C, vitamin A, serat, dan beberapa mineral penting. Buah ini juga mengandung enzim seperti amilase, yang dapat membantu pencernaan. Mangga memiliki biji besar di bagian tengahnya, yang dapat berbentuk pipih atau lonjong, tergantung pada jenis mangga. Selain rasanya yang enak, buah mangga memiliki sejarah panjang sebagai simbol kemakmuran dan keberuntungan dalam banyak budaya. Mangga dapat dikonsumsi segar, diolah menjadi jus, dikukus, dijadikan es krim, atau digunakan dalam berbagai hidangan kuliner, mulai dari salad buah hingga hidangan utama. Buah mangga tumbuh pada pohon mangga yang hijau sepanjang tahun di iklim tropis, dan musim panen dapat bervariasi tergantung pada varietas dan lokasi pertumbuhan. Dengan citra tropisnya dan rasa yang memikat, mangga telah menjadi buah favorit di seluruh dunia.



Gambar 2.1 Buah Mangga

Perbedaan tingkat, muda, matang, busuk pada buah mangga, mengalami transformasi visual dan sensoris yang signifikan selama proses pematangan, menciptakan perbedaan yang jelas antara tingkat, muda, matang, dan busuk. Berikut adalah deskripsi perbedaan karakteristik masing-masing tingkat kematangan pada buah mangga:

#### 1) Mangga Muda

Kulit mangga muda umumnya berwarna hijau busuk atau hijau gelap, memiliki tekstur daging yang keras dan kurang berair, rasanya sering kali astringen dan lebih bersifat asam dan memiliki aroma yang kurang intens dan khas mangga belum sepenuhnya terbentuk.

#### 2) Mangga Matang

Kulit mangga matang memiliki warna kulit mencapai puncak kematangannya, bisa kuning, oranye, atau merah, tergantung pada varietas. Memiliki daging yang lembut, *juicy*, dan mudah dipotong. Rasa manis yang khas dan dominan, dengan tingkat keasaman yang berkurang dan memiliki aroma mangga yang khas dan kuat mulai terasa.

#### 3) Mangga Busuk

Mangga busuk memiliki warna kulit yang bisa terlalu lembek, gelap, dan mungkin muncul bintik-bintik coklat. Memiliki daging yang sangat lembut, bahkan bisa terlalu lembek atau sedikit berair. Rasa manis yang berlebihan, mungkin disertai dengan rasa fermentasi atau alkohol dan aroma yang terlalu kuat dan kadang-kadang terlalu berfermentasi.

## 2.2 *Machine Learning*

*Machine Learning* (ML) adalah bagian dari kecerdasan buatan yang berfokus pada pengembangan algoritma dan model statistik yang memungkinkan komputer melakukan tugas tertentu tanpa menggunakan instruksi eksplisit. Sebaliknya, sistem ML belajar dan membuat prediksi berdasarkan data. Algoritma ini membangun model berdasarkan data sampel, yang dikenal sebagai "data pelatihan", untuk membuat prediksi atau keputusan tanpa diprogram secara eksplisit untuk melakukan tugas tersebut.

Pada penelitian lain yang dilakukan Menurut (Anastassia Amellia Kharis and Haqqi Anna Zili, 2022), pembelajaran mesin adalah metode mengajarkan mesin untuk memahami dan mengambil keputusan berdasarkan berbagai data yang diberikan. (Arsitektur, Arsitektur and Soegijapranata, 2021) mendefinisikan pembelajaran mesin sebagai teknologi yang dihasilkan dari kemajuan algoritma yang memungkinkan komputer memproses data menjadi tindakan dan mengubah data yang ada menjadi informasi.

*Machine Learning* (ML) adalah bidang dalam AI yang berfokus pada memungkinkan mesin mempelajari dan memecahkan masalah dengan cara yang mirip dengan manusia. Seperti namanya, ML melibatkan pembuatan program yang dirancang untuk meniru perilaku dan keterampilan manusia, sehingga memungkinkan mereka untuk menggeneralisasi data. Ada dua aplikasi utama *Machine Learning* : klasifikasi dan prediksi. Ciri khas ML adalah proses pelatihan dan pembelajarannya yang membutuhkan data yang disebut dengan data pelatihan. Klasifikasi adalah metode yang digunakan mesin untuk mengkategorikan objek

berdasarkan karakteristik tertentu, seperti cara manusia membedakan objek melalui eksperimen. Prediksi, di sisi lain, melibatkan perkiraan hasil berdasarkan data yang dipelajari selama pelatihan (Roihan, Sunarya and Rafika, 2020)

### 2.3 *Red Green Blue (RGB)*

*Red Green Blue (RGB)* adalah metode yang banyak digunakan untuk merepresentasikan warna dalam sistem digital, seperti komputer dan kamera. Hal ini didasarkan pada teori warna aditif, di mana warna diciptakan dengan menggabungkan intensitas cahaya merah, hijau, dan biru yang berbeda.

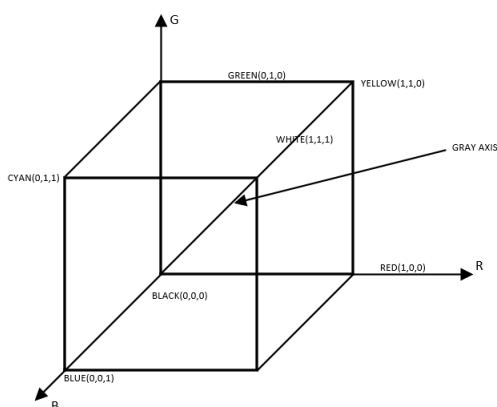
Dasar-dasar RGB adalah *Red* (R), salah satu warna primer dalam model RGB. Bagian merah pada gambar RGB menentukan intensitas warna *red* pada gambar. *Green* (G), warna primer lainnya adalah *green* mengontrol intensitas warna hijau. *Blue* (B): Warna primer ketiga dalam model RGB. Bagian *blue* mengontrol intensitas warna *blue*.

Dalam model RGB, warna diciptakan dengan mencampurkan intensitas cahaya *red*, *green*, *blue* yang berbeda. Setiap bagian warna (R, G, dan B) dapat memiliki nilai yang berkisar antara 0 hingga 255. Dengan menggabungkan nilai-nilai ini, berbagai macam warna dapat direpresentasikan.

- 1) Hitam: (0, 0, 0) – Tidak ada warna, tidak ada cahaya.
- 2) Putih: (255, 255, 255) – Intensitas penuh ketiga warna.
- 3) Warna Primer: Merah (255, 0, 0), Hijau (0, 255, 0), Biru (0, 0, 255).
- 4) Warna Sekunder: Kuning (255, 255, 0), Cyan (0, 255, 255), Magenta (255, 0, 255).

Adapun RGB dalam pencitraan digital dan grafik, model RGB digunakan untuk merepresentasikan dan menampilkan gambar. Setiap piksel dalam suatu gambar diwakili oleh kombinasi nilai merah, hijau, dan biru. Nilai-nilai ini menentukan warna dan kecerahan piksel. Penerapan RGB dalam pemrosesan sangat penting dalam tugas pemrosesan gambar, seperti koreksi warna, pemfilteran, dan transformasi.

RGB adalah metode representasi warna yang umum digunakan dalam grafik komputer. Terdiri dari tiga warna: merah, hijau, dan biru, dari mana namanya berasal. Dalam bahasa Inggris dilambangkan dengan (r)ed, (g)reen, dan (b)lue. Ketiga warna ini diwakili oleh angka mulai dari 0 hingga 1. Nilai numerik ini dapat digunakan dalam persamaan matematika. Oleh karena itu, kombinasi keduanya dapat direpresentasikan dengan garis tiga dimensi. Garis ini membentuk kubus, seperti diilustrasikan pada gambar di bawah (Manik et al., 2017).



Gambar 2.2 Grafik RGB

Gambar 2.2, nilai RGB dihitung, yang mewakili format pewarnaan yang paling umum digunakan. Diagram pada Gambar 2.4 memberikan informasi tentang

distribusi warna RGB. Menentukan nilai RGB sangatlah mudah, karena nilai tersebut dimasukkan ke dalam masing-masing kolom matriks: kolom 1 menunjukkan warna *red*, kolom 2 menunjukkan warna *green*, dan kolom 3 menunjukkan warna *blue*.

$$\begin{aligned} fR &= data(:, :, 1); \\ fG &= data(:, :, 2); \dots\dots\dots(1.1) \\ fB &= data(:, :, 3); \end{aligned}$$

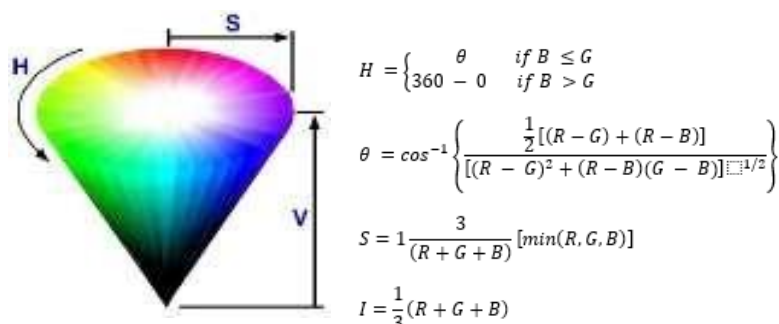
Untuk menentukan nilai RGB, kita dapat mengekstrak nilai maksimum, nilai minimum, dan nilai rata-rata. Di sini penulis memilih nilai rata-rata yang muncul dari setiap piksel, sehingga sangat mudah untuk menemukan hasil nilai rata-rata RGB yang keluar dari suatu objek.

$$\begin{aligned} fr &= mean(mean(fR)); \\ fb &= mean(mean(fG)); \dots\dots\dots(1.2) \\ fc &= mean(mean(fB)); \\ frr &= fr/255; \\ fbb &= fb/255; \dots\dots\dots(1.3) \\ fcc &= fc/255; \end{aligned}$$

#### 2.4 Hue Saturation Intensity (HSI)

Perhitungan ruang warna HSI (*Hue, Saturation, Intensity*) merupakan bagian integral dari pemrosesan gambar, memfasilitasi dan menyederhanakan deteksi dan identifikasi warna. Meskipun identifikasi menggunakan RGB cukup efektif, namun mungkin tidak cocok untuk aplikasi pemrosesan gambar tertentu

dalam berbagai bentuk. Aplikasi pengenalan objek lebih mudah diidentifikasi menggunakan nilai HSI-nya, karena ada banyak objek gambar yang termasuk dalam rentang terang-gelapnya. Terang-gelap secara khusus disebut sebagai ruang warna, dimana setiap ruang memiliki titik terang dan gelapnya masing-masing dalam satu gambar. Kehadiran warna bertujuan untuk membakukan spesifikasi warna. Ruang warna sangat penting dalam preprocessing, segmentasi, dan pemilihan ruang warna yang tepat dapat mempengaruhi hasil segmentasi. Ada berbagai ruang warna yang tersedia saat ini, salah satunya adalah HSI. HSI memiliki kelas tiga dimensi: *Hue* (H), *Saturation* (S), dan *Intensity* (I). *Hue* mewakili warna-warna dasar seperti *red*, *green* dan *blue* atau kombinasinya. Saturasi menunjukkan ketajaman warna dalam *Hue*. Dan Intensitas adalah kecerahan rona dan saturasi.



Gambar 2.3 Rumus *Hue Saturation Intensity*

## 2.5 *K-Nearest Neighbor (KNN)*


Algoritma *K-Nearest Neighbor* (KNN) merupakan metode yang digunakan untuk mengklasifikasikan objek berdasarkan titik data latih terdekat pada ruang fitur. Data pelatihan diproyeksikan ke dalam ruang multidimensi, di mana setiap dimensi mewakili fitur data (Saputra et al., 2023). KNN adalah algoritma



pembelajaran terawasi, artinya algoritma ini bertujuan untuk menemukan pola baru dalam data dengan menghubungkan pola yang diketahui dengan data baru. Sebaliknya, pembelajaran tanpa pengawasan bertujuan untuk menemukan pola dalam data yang tidak memiliki label sebelumnya (Rambe, Tanjung and Muhathir, 2022).

Tujuan dari algoritma KNN adalah untuk mengklasifikasikan objek baru berdasarkan atributnya dan sampel pelatihan. Ia menggunakan klasifikasi lingkungan sebagai nilai prediksi untuk contoh data pengujian baru. Metrik jarak yang digunakan biasanya adalah Jarak Euclidean (Muniar, Pasnur and Lestari, 2020).

Jarak Euclidean adalah metrik yang paling umum digunakan untuk data numerik. Algoritma KNN menghitung jarak antara data uji dan data latih, dan klasifikasi didasarkan pada tetangga terdekat dengan jarak terkecil (Ismanto and Wardoyo, 2016).



Gambar 2.4 Cara Kerja *K-Nearest Neighbors*

Di Gambar 2.4 *K-Nearest Neighbors*, data yang dapat diklasifikasikan tidak terbatas pada nilai numerik; itu juga dapat digunakan untuk mengklasifikasikan data gambar. Terlebih lagi, algoritma *K-Nearest Neighbors* terbukti memiliki akurasi yang kompetitif jika dibandingkan dengan algoritma lain seperti *support vector machine*, sebagaimana disebutkan dalam salah satu jurnal: “Hasil penelitian menunjukkan bahwa akurasi klasifikasi menggunakan metode KNN sama baiknya dengan metode SVM.” Karena *K-Nearest Neighbors* termasuk dalam pembelajaran yang diamati, data pelatihan yang dimasukkan ke dalam model secara signifikan memengaruhi hasil prediksi untuk data baru. (Farsia et al., 2013)

Dalam penelitian lain yang dilakukan Laina Farsiah dan Taufik Pamungkas bertajuk “Ekstraksi Citra Menggunakan Metode SVM dan KNN pada Bunga Angrek”, mereka mengeksplorasi perbandingan metode SVM dan KNN dalam hal metodologi dan akurasi dalam mengklasifikasikan citra berwarna. Penelitiannya melibatkan pengujian berbagai jenis gambar, termasuk orang, bangunan, tanaman, dan lain-lain. Hasil perbandingan akhir menunjukkan bahwa akurasi klasifikasi citra menggunakan metode *K-Nearest Neighbors* sama efektifnya dengan menggunakan metode *Support Vector Machine*. (Pamungkas, 2019).

## **2.6 Deteksi Citra**

Deteksi citra adalah proses mengidentifikasi dan menentukan lokasi objek, pola, atau fitur tertentu dalam citra digital. Tujuan dari deteksi citra adalah untuk mengetahui keberadaan dan lokasi relatif objek atau fitur tertentu dalam suatu citra. Hal ini dapat dicapai dengan menggunakan berbagai teknik dan algoritma dalam

pengolahan citra, termasuk penggunaan filter, segmentasi, dan analisis pola. Deteksi gambar memiliki berbagai aplikasi, termasuk pengenalan wajah, deteksi objek dalam visi komputer, pengawasan keamanan, dan bidang lain yang memerlukan identifikasi dan lokalisasi objek dalam gambar digital (Riyadi et al., 2022).

Analisis citra bertujuan untuk mengidentifikasi berbagai parameter dari ciri-ciri objek pada suatu citra untuk tujuan interpretasi. Prosesnya melibatkan tiga langkah utama: ekstraksi fitur, segmentasi, dan klasifikasi. Ekstraksi fitur melibatkan penelusuran tepi objek dalam suatu gambar, sedangkan segmentasi melibatkan pengurangan gambar menjadi objek. Terakhir, klasifikasi menetapkan segmen yang berbeda ke kelas objek dengan nilai berbeda. Dalam studi kasus ini, analisis gambar memastikan bahwa setiap gambar yang memiliki kesamaan diberi label sesuai dengan data pelatihan. Untuk data baru, analisis citra mengidentifikasi citra dalam dataset yang mempunyai kemiripan signifikan (tetangga) dengan data baru (Aritonang, 2020).

## 2.7 Matlab

Matlab adalah *platform* yang menggabungkan lingkungan desktop yang dioptimalkan untuk desain dan analisis dengan bahasa pemrograman yang mendukung operasi matriks. Bahasa matlab memungkinkan operasi matematika, visualisasi data, dan pemrograman untuk tugas-tugas kompleks (Laksono, 2017).

Matlab memiliki beberapa komponen utama. Lingkup komponen Utama matlab, yaitu :

1. *Command Window*: tempat pengguna dapat mengetik perintah dan melihat hasilnya secara langsung.
2. *Workspace*: area yang menampilkan variabel yang sedang aktif.
3. *Command History*: menyimpan daftar perintah yang telah dieksekusi.
4. Editor: tempat untuk menulis, mengedit, dan menyimpan skrip MATLAB dan fungsi.

Matlab juga memiliki banyak fungsi salah satunya adalah untuk pemrosesan citra/gambar pada pemrosesan citra/gambar digital. Adapun Toolbox pemrosesan citra/gambar diantaranya adalah menyediakan fungsi untuk :

1. Membaca dan menampilkan citra

```
I = imread('image.jpg');           % Membaca citra dari file
imshow(I);                          % Menampilkan citra
```

2. Konversi Ruang warna

```
I_gray = rgb2gray(I);             % Mengonversi citra RGB ke grayscale
imshow(I_gray);                   % Menampilkan citra grayscale
```

3. Ekstraksi Fitur

```
edges = edge(I_gray, 'Canny'); % Deteksi tepi menggunakan metode
Canny
imshow(edges);                     % Menampilkan hasil deteksi tepi
```

4. Analisis Data dan Visualisasi, berfungsi untuk menganalisis data dan pembuatan grafik.

1. Statistik

```
data = randn(1000,1); % Membuat data acak dengan distribusi normal
```

```
mean_data = mean(data); % Menghitung rata-rata data  
std_data = std(data); % Menghitung standar deviasi data  
histogram(data); % Membuat histogram dari data
```

## 5. Algoritma Klasifikasi

### 1. Membangun Model K-Nearest Neighbors (KNN)

```
X = [1 2; 2 3; 3 4]; % Data latih
```

```
Y = [1; 2; 1]; % Label data
```

## 2.8 Penelitian Terkait dan Kebaruan Penelitian

Tantangan penelitian dijawab dengan memperluas *state-of-the-art* bidang penelitian dengan memasukkan unsur-unsur tambahan yang dapat memenuhi kebutuhan klasifikasi kematangan buah mangga dengan metode pendekatan citra menggunakan *K-Nearest Neighbor*.

Tabel 2.1 *State of The Art* Penelitian

No	Penulis	Judul	Metode Klasifikasi	Hasil Penelitian
1.	(Nafi'iyah, 2019).	Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV dengan KNN	<i>K-Nearest Neighbor</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV)	Penelitian ini memanfaatkan ruang warna <i>K-Nearest Neighbor</i> (K-NN) dan HSV untuk menentukan kematangan mangga. Berdasarkan pengujian yang dilakukan dapat disimpulkan bahwa penerapan metode K-NN dapat efektif diterapkan pada sistem klasifikasi kematangan mangga berdasarkan warna HSV. Data pengujian menghasilkan akurasi rata-rata 55% dengan rentang jarak k=1-10.
2.	(Muhammad, Ermatita and Falih, 2021).	Penggunaan <i>K-Nearest Neighbor</i> (KNN) untuk Mengklasifikasi Citra Belimbing Berdasarkan Fitur Warna	<i>K-Nearest Neighbor</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV).	Penelitian ini juga menggunakan metode KNN dan ekstraksi warna HSV untuk klasifikasi citra belimbing wuluh. Berdasarkan uji coba yang dilakukan, algoritma KNN dengan jarak K=7 berhasil mengklasifikasikan karakteristik HSV pada citra belimbing wuluh memiliki keakuratan

				sebesar 93.33%.
3.	(Amrozi et al., 2022)	Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM	<i>Support Sector Machine</i> (SVM) dan <i>Red, Gred, Blue</i> (RGB)	Hasil penelitian ini ditunjukkan dengan matriks konfusi dengan nilai True Positive (TP) sebesar 0,82, nilai False Positive (FP) sebesar 0,18, nilai False Negative (FN) sebesar 0,02, dan nilai True Negative (TN) sebesar 0,98. Menggabungkan warna, fitur tekstur, dan pengukuran bentuk menggunakan SVM menghasilkan hasil yang sangat akurat. Eksperimen mencapai akurasi klasifikasi yang signifikan sebesar 89,86%.
4.	(Cek et al., 2022).	Identifikasi Kesegaran Ikan Menggunakan Algoritma KNN Berbasis Citra Digital	<i>K-Nearest Neighbor</i> (KNN) dan <i>Red, Green, Blue</i> (RGB)	Penelitian ini menggunakan metode KNN dan ekstraksi RGB untuk menentukan kesegaran ikan. Hasil pengujian menunjukkan akurasi tertinggi dicapai dengan K=1 yaitu mencapai 93,33%. Berdasarkan keakuratan tersebut, metode KNN dapat menjadi model yang layak untuk mengembangkan identifikasi kesegaran ikan menggunakan citra digital.
5.	(Salsabila, Yunita and Rozikin, 2021).	Identifikasi Citra Jenis Bunga menggunakan Algoritma KNN dengan Ekstraksi Warna HSV dan Tekstur GLCM	<i>K-Nearest Neighbor</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV).	Penelitian ini menggunakan metode KNN dengan ekstraksi HSV. Penerapan algoritma K-Nearest Neighbor dan ekstraksi fitur warna dan tekstur sangat memudahkan pemrosesan gambar untuk identifikasi bunga, mengurangi waktu dan meningkatkan kemudahan, dengan akurasi

				tertinggi sebesar 71% dicapai dengan menggunakan K=7.
6.	(Wijaya and Ridwan, 2019).	Klasifikasi Jenis Buah Apel Dengan Metode <i>K-Nearest Neighbors</i>	<i>K-Nearest Neighbors</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV)	Penelitian menunjukkan bahwa hasil evaluasi metode <i>K-Nearest Neighbor</i> menghasilkan rata-rata keseluruhan Presisi sebesar 94%, Recall sebesar 100%, dan Akurasi sebesar 94%.
7.	(Sanjaya et al., 2019).	<i>K-Nearest Neighbor</i> for Classification of Tomato Maturity Level Based on Hue, Saturation, and Value Colors	<i>K-Nearest Neighbor</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV)	Untuk gambar tomat, pengujian ukuran piksel 100x100, 300x300, 600x600, dan 1000x1000 piksel menghasilkan akurasi tertinggi sebesar 92,5% untuk gambar 1000x1000 piksel dengan nilai lingkungan 3.
8.	(Wibowo et al., 2021).	Deteksi Kematangan Buah Jambu Kristal Berdasarkan Fitur Warna Menggunakan Metode Transformasi Ruang Warna Hsv ( <i>Hue Saturation Value</i> ) Dan <i>K-Nearest Neighbor</i>	<i>K-Nearest Neighbor</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV).	Penelitian buah jambu kristal, tingkat keberhasilannya sebesar 91,67%, dengan 55 pembacaan benar dan 5 pembacaan salah dari 60 sampel buah matang, dan 90% untuk buah muda dengan 36 pembacaan benar dan 4 pembacaan salah dari 40 sampel.
9.	(Rachmawanto and Hadi, 2021).	Optimasi Ekstraksi Fitur Pada KNN Dalam Klasifikasi Penyakit Daun Jagung	<i>K-Nearest Neighbor</i> (KNN) dan <i>Hue, Saturation, Value</i> (HSV).	Penelitian ini menunjukkan bahwa dari 160 citra latih dan 40 citra uji dengan menggunakan algoritma KNN-HSV-GLCM, akurasi tertinggi yang dicapai sebesar 85% dengan k=3 dan jarak piksel 1. Akurasi terendah sebesar 70% dengan k=3 dan a jarak piksel 3.
10.	(Arkadia, Ayu Damayanti and	Klasifikasi Buah Mangga Badami Untuk Menentukan	<i>Convolutional Neural Network</i> (CNN) dan <i>Red,</i>	Penelitian ini menggunakan metode CNN dengan ekstraksi warna RGB. Pengujian



	Sandya Prasvita, 2021).	Tingkat Kematangan dengan Metode CNN	<i>Green, Blue</i> (RGB)	tersebut melibatkan 25 gambar uji dan 179 gambar latih dari total 204 gambar, sehingga mencapai akurasi model sebesar 97,2%.
11.	(Wardani, Wijaya and Bimantoro, 2022)	Klasifikasi Jenis dan Tingkat Kematangan Buah Pepaya Berdasarkan Fitur Warna, Tekstur dan Bentuk Menggunakan <i>Support Vector Machine</i> .	<i>Support Vector Machine</i> (SVM) dan <i>Hue, Saturation, Intensity</i> (HIS)	Penelitian menunjukkan total 600 gambar pepaya yang digunakan, dibagi menjadi data latih dan uji. Akurasi tertinggi untuk dataset Bangkok adalah 66% dengan fitur HSI, dan untuk dataset California sebesar 65% dengan fitur HSI.
12.	(Wandi, Fauziah and Hayati, 2021).	Deteksi Kelayuan Bunga Mawar Dengan Metode Transformasi Ruang Warna HSI dan HSV	<i>K-Nearest Neighbor</i> (KNN), <i>Hue, Saturation, Value</i> (HSV) dan <i>Hue, Saturation, Intensity</i> (HIS).	Studi ini juga menunjukkan tingkat keberhasilan 92,3% untuk pengujian bunga mawar menggunakan HSI, dengan 757 pembacaan benar dan 63 pembacaan salah dari 820 sampel. Untuk HSV, tingkat keberhasilannya adalah 93,2%, dengan 765 pembacaan benar dan 55 pembacaan salah dari 820 sampel. Berdasarkan hasil tersebut, transformasi ruang warna HSV terbukti menjadi metode terbaik untuk mendeteksi kelayuan bunga mawar.
13.	(Astari, Wijaya and Widiartha, 2021)	Klasifikasi Jenis dan Tingkat Kesegaran Daging Berdasarkan Warna, Tekstur dan Invariant Moment Menggunakan Klasifikasi LDA	<i>Support Vector Machine</i> (SVM), <i>Gray-Level Co-occurrence Matrix</i> dan <i>Hue, Saturation, Intensity</i> (HSI)	Penelitian ini menunjukkan bahwa total 960 gambar dari 3 jenis daging berbeda yaitu ayam, kambing, dan sapi, Akurasi tertinggi yang diperoleh sebesar 90% menggunakan kombinasi fitur HSI dan momen invarian untuk daging yang disimpan di lemari es.

## 2.9 Relevansi Penelitian

Tabel 2.2 menunjukkan perbandingan capaian yang akan didapatkan pada penelitian ini dengan capaiann yang telah didapatkan oleh penelitian sebelumnya.

Tabel 2.1 Matriks penelitian

No	Penelitian	Ruang Lingkup										
		Classification							Parameter uji			
		KNN	CNN	SVM	HSI	HSV	RGB	GLCM	<i>accuracy</i>	<i>Recall</i>	<i>Precision</i>	<i>f1 score</i>
1.	(Nafi'iyah, 2019).	✓	-	-	-	✓	-	-	✓	-	-	-
2.	(Muhammad, Ermatita and Falih, 2021).	✓	-	-	-	-	✓	-	✓	-	-	-
3.	(Amrozi et al., 2022)	-	-	✓	-	-	✓	-	✓	✓	-	-
4.	(Cek et al., 2022).	✓	-	-	-	-	✓	-	✓	-	-	-
5.	(Salsabila, Yunita and Rozikin,	✓	-	-	-	✓	-	✓	✓	-	-	-

	2021).											
6.	(Wijaya and Ridwan, 2019).	✓	-	-	-	✓	-	-	✓	✓	✓	-
7.	(Sanjaya et al., 2019).	✓	-	-	-	✓	-	-	✓	-	-	-
8.	(Wibowo et al., 2021).	✓	-	-	-	✓	-	-	✓	-	-	-
9.	(Rachmawanto and Hadi, 2021).	✓	-	-	-	✓	-	✓	✓	-	-	-
10	(Arkadia, Ayu Damayanti and Sandya Prasvita, 2021).	-	✓	-	-	-	✓	-	✓	-	-	-
11	(Wardani, Wijaya and Bimantoro, 2022)	-	-	✓	✓	-	✓	-	✓	-	-	-
12.	(Wandi, Fauziah and Hayati,	✓	-	-	✓	✓	-	-	✓	-	-	-

	2021).											
13.	(Astari, Wijaya and Widiartha, 2021)	-	-	✓	✓	-	✓	-	✓	-	-	-
14.	Penelitian	✓	-	-	✓	-	✓	-	✓	✓	✓	✓

### 2.10 Kebaruan Penelitian

Berdasarkan penelitian sebelumnya yang telah diuraikan, penelitian ini memberikan sudut pandang baru dengan menggunakan dua model dalam image processing, yaitu RGB dan HSI. Pada penelitian sebelumnya, fokus penelitian lebih banyak pada penggunaan model klasifikasi dengan satu model image processing, tetapi penelitian ini memberi sudut pandang baru dan lebih luas dengan menggunakan HSI sebagai model image processing utama dan diikuti dengan penggunaan nilai RGB sebagai parameter tambahan untuk memperkuat argumen pada parameter uji. Perlu diketahui bahwa nilai HSI bersifat ketergantungan dengan nilai RGB, artinya tanpa nilai RGB, HSI tidak dapat menentukan warna sesungguhnya, sehingga perlu tambahan parameter RGB untuk memperkuat argumen klasifikasi dengan menggunakan transformasi ruang warna HSI. Sehingga, penelitian ini menawarkan sudut pandang yang tidak hanya lebih luas tetapi lebih baru dengan mengikutsertakan penggunaan nilai RGB sebagai parameter pendukung.