

## **Analisa Fitur Ekstraksi Ciri dan Warna Dalam Proses Klasifikasi Kematangan Buah Rambutan Berbasis K-Nearest Neighbor**

**Heru Pramono Hadi<sup>1\*</sup>, Eko Hari Rachmawanto<sup>2</sup>**

<sup>1,2</sup>Fakultas Ilmu Komputer, Universitas Dian Nuswantoro, Semarang, Indonesia

E-mail: <sup>1</sup>heru.pramono.hadi@dsn.dinus.ac.id, <sup>2</sup>eko.hari@dsn.dinus.ac.id

(\* : corresponding author)

### **Abstrak**

Klasifikasi citra buah rambutan leci, lengkeng, pulasan dan rambutan yang merupakan buah dalam stau spesies telah dilakukan. Klasifikasi buah rambutan menggunakan KNN saja atau fitur ekstraksi saja sudah pernah dilakukan. Dalam penelitian ini, proses klasifikasi kematangan buah rambutan dilakukan dengan K-NN berbasis fitur ekstraksi ciri dan warna dengan tujuan untuk meningkatkan akurasi klasifikasi citra. Terpilih ekstraksi ciri GLCM dan ekstraksi ciri warna HSV, dimana masing-maisng mempunyai keunggulan masing-masing. Berdasarkan 100 dataset citra dalam 4 kelas yaitu mentah, setengah matang, matang dan busuk, telah dilakukan percobaan bervariasi menggunakan sudut GLCM dari  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  dan nilai K=1,3,5,7,9,11,13. Akurasi terbaik yang dihasilkan yaitu 97,5% pada K=1 dan  $0^\circ$ . Sedangkan yang terendah pada K=13 dan  $135^\circ$  dengan hasil 62,5%.

Kata kunci: K-NN, rambutan, klasifikasi, GLCM, HSV

### **Abstract**

*Classification of images of rambutan lychee, longan, outward appearance and rambutan which is a fruit in one species has been carried out. Classification of rambutan fruit using only KNN or feature extraction has been done. In this study, the ripeness classification process of rambutan fruit was carried out using K-NN based on feature and color feature extraction with the aim of increasing the accuracy of image classification. Selected GLCM feature extraction and HSV color feature extraction, each of which has its own advantages. Based on 100 image datasets in 4 classes, namely raw, undercooked, ripe and rotten, various experiments have been carried out using GLCM angles of  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  and the value of K=1,3,5,7,9,11,13. The best accuracy obtained is 97.5% at K=1 and  $0^\circ$ . While the lowest is at K=13 and  $135^\circ$  with a result of 62.5%.*

*Keywords:* K-NN, rambutan, classification, GLCM, HSV

## **1. PENDAHULUAN**

Rambutan berasal dari Kepulauan Melayu dan telah dibudidayakan secara luas di seluruh wilayah di Thailand, Vietnam Selatan, Indonesia, Filipina, India, dan Sri Lanka. Di Malaysia rambutan dibudidayakan di hampir semua bagian negara, tetapi terutama di negara bagian Perak, Pahang, Kedah, Kelantan, Johor dan Terengganu [1]. Iklim tropis negara-negara tersebut di atas dicirikan oleh curah hujan yang tinggi dan merata, kelembaban tinggi, tingkat penguapan yang rendah dan suhu minimum rata-rata di atas  $20^\circ\text{C}$ . Rambutan tumbuh subur dengan baik di bawah kondisi ini dan menghasilkan buah berkualitas baik. Iklim yang hangat sangat ideal untuk pertumbuhan dan hasil yang tinggi. Sangat cocok untuk sebagian besar jenis tanah, kecuali daerah yang tergenang air dan gambut. Rambutan membutuhkan banyak kelembaban, tidak cocok di medan berbukit dan tidak berkinerja baik di daerah berpasir. Tanah aluvial dalam dan tanah yang mengandung bahan organik tinggi sangat ideal untuk pertumbuhan dan perkembangannya. Tanah ini membutuhkan drainase yang tepat. Rambutan lebih menyukai pH sekitar 5,5–6,5. Pada tanah alkali, masalah mikronutrien sering berkembang.

Rambutan adalah pohon berukuran sedang yang menghasilkan buah berwarna merah atau kuning berbentuk bulat sampai lonjong dengan rambut atau tuberkel pada kulitnya seperti ditunjukkan pada Gambar 1, daging buahnya bening dan manis. Kebanyakan pohon rambutan yang diperbanyak dari biji tidak benar-benar jenisnya dan biasanya asam. Kadang-kadang, orang

mungkin memperhatikan pohon rambutan jantan. Tergantung pada lokasinya, pohon rambutan menghasilkan satu atau dua kali panen dalam setahun. Di Asia, rambutan menghasilkan panen kecil antara Juni dan Juli, dan panen besar antara November dan Januari. Klon yang dipilih menghasilkan daging yang tebal, padat, manis. Sejumlah besar klon rambutan tersedia di Asia Tenggara dan Australia. Seseorang harus hati-hati memilih klon yang beradaptasi dengan baik, karena beberapa klon bekerja dengan baik hanya di lingkungan tertentu tetapi tidak di daerah lain.



Gambar 1. Penampakan Visual Buah Rambutan

Lima belas minggu setelah buah matang, mereka matang dan warnanya berubah dari hijau menjadi kuning-hijau, kuning, oranye kekuningan atau merah. Petani saat ini memanen rambutan berdasarkan pengetahuan yang dikumpulkan selama bertahun-tahun oleh petani dan penasihat pertanian, yang memutuskan penampilan buah, atau dengan menghitung hari dari set buah. Perkembangan warna merah merupakan indeks panen utama untuk kultivar merah. Perubahan warna ini perlu dikaitkan dengan fitur lain seperti rasa, rasa dan sifat fisik. Bobot buah, pericarp atau kulit, pulp dan biji dianggap menentukan kematangan. Kandungan minimum padatan terlarut 16% juga dapat digunakan sebagai indikator. Namun, kultivar bervariasi dalam kandungan maksimum padatan terlarut dari 17 hingga 21% pada saat jatuh tempo penuh. Studi tentang komposisi kimia varietas rambutan R3 dan R165 pada berbagai tahap kematangan menunjukkan bahwa total padatan terlarut, gula dan pati meningkat, sedangkan keasaman yang dapat dititrasi menurun seiring dengan kematangan. Pada perkembangan warna penuh buah rambutan, total padatan terlarut dan persentase gula tertinggi, sedangkan total keasaman terendah untuk kedua klon. Warna buah memainkan peran penting tidak hanya untuk berat aril yang optimal [2], tetapi juga untuk kualitas buah yang optimal.

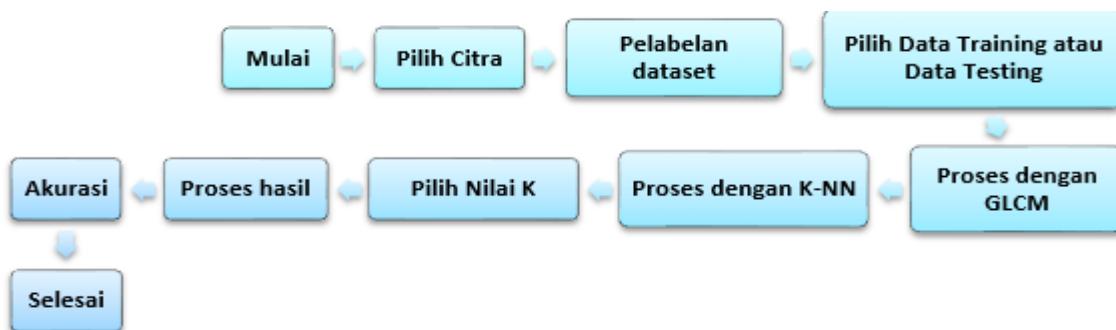
Sistem komputer vision adalah salah satu metode yang paling umum digunakan untuk estimasi hasil berbagai tanaman, seperti apel, rambutan, lengkeng, anggur dan jeruk. Beberapa penelitian telah berfokus pada estimasi dan pemetaan hasil buah non-destructif berbasis visi mesin. Untuk deteksi apel, [2] mengembangkan metode untuk mendeteksi rambutan secara otomatis menggunakan pencitraan hiperspektral, dan tingkat deteksi yang benar secara keseluruhan adalah 87% dengan tingkat kesalahan 15%. [3] menyarankan bahwa peta distribusi pembungaan buah dapat digunakan untuk pemetaan hasil, dan korelasi model antara kepadatan bunga yang ditentukan dari analisis citra dan hasil buah. Hasil mereka menunjukkan bahwa potensi hasil dapat diprediksi di awal musim dari peta distribusi pembungaan dan dapat digunakan untuk pengelolaan kebun selama musim tanam. [4] mengusulkan algoritma pengenalan kiwi dengan perbedaan warna seperti merah dikurangi biru (RB), dan hijau dikurangi merah (GR). Koefisien determinasi ( $R^2$ ) antara apel yang dideteksi oleh algoritma penghitungan buah dan hasil panen aktual berkisar antara 0,57 untuk buah muda hingga 0,70 untuk buah dalam periode pematangan buah. Untuk deteksi buah jeruk oleh [5]. mengembangkan sistem penglihatan warna untuk memperkirakan hasil jeruk. [6] mengembangkan metode identifikasi buah menggunakan transformasi DAS untuk memisahkan dan membelah buah yang bersentuhan untuk penghitungan buah dan estimasi hasil yang akurat. [7] melengkapi kamera inframerah-dekat monokromatik dengan filter pita optik yang dapat dipertukarkan untuk menangkap gambar buah jeruk untuk

identifikasi jeruk hijau muda di lapangan, dan hasilnya mengungkapkan potensi sistem pencitraan multispektral untuk digunakan dalam sistem pemetaan hasil awal musim otomatis. [8] mengembangkan metode pemrosesan citra hiperspektral untuk mendeteksi buah jeruk hijau yang belum matang di masing-masing pohon, dan tes deteksi buah mengungkapkan bahwa 80–89% buah di latar depan set validasi telah diidentifikasi dengan benar, meskipun banyak yang terhalang atau buah yang sangat kontras diidentifikasi secara tidak benar. Baru-baru ini, [9] mengembangkan pendekatan eigenvector baru untuk mendeteksi buah manggis yang belum matang dari gambar berwarna yang diperoleh di bawah kondisi luar ruangan alami dan melaporkan akurasi deteksi 75%. Sedangkan pada penelitian [10] menerapkan teknik baru yang memanfaatkan nilai kebocoran transformasi Fourier cepat untuk mendeteksi leci yang belum menghasilkan, dan memperoleh akurasi 82% untuk identifikasi buah yang benar.

Pada makalah ini, untuk mendeteksi kematangan buah rambutan diperlukan algoritma yang cocok untuk data berukuran sedikit hingga sedang dan perhitungan kelas yang akurat berdasarkan jarak piksel sehingga dipilih algoritma K-Nearest Neighbor. Dengan tujuan peningkatan akurasi, diperlukan adanya preprosesing seperti ekstraksi ciri dan warna. Dalam penelitian ini, dipilih ekstraksi ciri GLCM dan ekstraksi warna HSV untuk memperoleh akurasi yang optimal.

## 2. METODE PENELITIAN

### 2.1. Usulan Metode



Gambar 2. Alur Tahapan Penelitian

Berdasarkan Gambar 2, tahapan penelitian dapat dijabarkan menjadi:

- Citra yang akan dipilih di *load* terlebih dahulu ke dalam folder yang sudah disiapkan dan akan dipanggil dalam tombol “browse” pada menu Graphical User Interface (GUI).
- Pilih citra yang akan diproses, yaitu citra training atau citra testing sesuai label dataset.
- Lakukan ekstraksi ciri GLCM dengan nilai  $d=1$ . Lakukan normalisasi data hingga dihasilkan nilai pada setiap fitur GLCM.
- Proses hasil perhitungan GLCM menggunakan K-NN dengan nilai  $K=1,3,5,7,9,11$ , dan 13.
- Didapatkan nilai akurasi dari masing-masing perubahan berdasarkan nilai  $K$  yang dipilih.

### 2.2. K-Nearest Neighbor

Klasifikasi citra merupakan tahapan dimana proses pengelompokan jenis citra berdasarkan kelasnya dari data citra latih yang telah diketahui hasil ekstrak tekturnya menggunakan GLCM dengan masukan dari data citra sampel uji [11]. Algoritma KNN digunakan untuk mengklasifikasikan citra/data siap uji berdasarkan citra data latih yang menjadi acuan algoritma KNN untuk menentukan kelass citra data uji menggunakan nilai  $k$ . Nilai  $k$  merupakan acuan jumlah tetangga terdekat dalam menentukan jenis kelas pada citra data uji [12]–[14]. Data citra latih dan data citra uji berupa hasil perhitungan GLCM. Setelah menentukan nilai  $k$ , selanjutnya dilakukan perhitungan jarak untuk menentukan kedekatan sampel data citra latih dan data citra uji.

Tahapan KNN secara umum, yaitu:

- a) Menentukan nilai K.
- b) Melakukan perhitungan jarak antara titik lama dan titik baru terhadap semua data yang digunakan.
- c) Melakukan perhitungan untuk mengetahui jarak terdekat dari data uji terhadap seluruh data latih.
- d) Melakukan pengurutan nilai jarak terdekat yang merupakan hasil dari point 3.
- e) Melakukan penentuan kelas baru yang merupakan hasil perhitungan terhadap citra uji.

K-nearest neighbor (KNN) classifier telah sangat berhasil dalam banyak aplikasi praktis. Mengingat vektor fitur  $x$  dan jarak yang tidak diketahui, aturan KNN mengklasifikasikan  $x$  dengan menetapkannya sebagai label yang paling sering diwakili di antara  $k$  tetangga terdekat dan mengambil peran. Ketika  $k = 1$ , vektor fitur ditugaskan ke kelas tetangga terdekatnya. Dalam penelitian ini, satu digunakan untuk  $k$ , dan jarak Euclidean digunakan untuk pengukuran jarak antar sampel. Perhitungan jarak kedekatan dapat menggunakan Euclidean Distance yang dapat dihitung dengan persamaan (1).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Dimana  $d$  = jarak;  $x$  = data pelatihan;  $y$  = data pengujian;  $i$  = jumlah tetangga terdekat; dan  $n$  = jumlah gambar.

### **2.3. Fitur Gray Level Co-Occurrence Matrix (GLCM)**

Ekstraksi fitur adalah prosedur reduksi data untuk menemukan subset dari variabel bermanfaat berdasarkan gambar. Dalam penelitian ini, tujuh fitur tekstur berdasarkan matriks tingkat keabuan (GLCM) diekstraksi dari setiap gambar. Matriks kejadian bersama adalah dihitung untuk empat arah:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  dan  $135^\circ$  derajat [3], [15], [16]. Fitur dari sebuah gambar adalah properti yang sepenuhnya menggambarkan gambar. Masalah di sebagian besar karya sebelumnya adalah kurangnya strategi pemilihan fitur yang efektif. Metode statistik ini menghitung *co-occurrence-matrix* dari setiap citra dalam database dengan menghitung seberapa sering suatu piksel dengan intensitas tertentu  $i$  muncul dalam hubungannya dengan piksel lain  $j$  pada jarak tertentu  $d$  dan orientasi [17].

Dalam makalah ini matriks dihitung hanya untuk satu arah ( $\theta=0$ ) dan satu jarak ( $d=1$ ). Matriks korelasi tingkat keabuan mengungkapkan fitur-fitur tertentu yang mempengaruhi distribusi spasial tingkat keabuan pada objek citra. Tiga belas fitur tekstur Haralick dihitung dari setiap matriks cooccurrence, menghasilkan himpunan vektor fitur. Selain fitur-fitur yang dijelaskan dalam [18] yang biasa digunakan dalam penelitian, dua fitur lain yang dijelaskan dalam [19], bernama cluster shade dan cluster prominence, memiliki pengaruh yang efektif dalam akurasi klasifikasi, namun tidak digunakan dalam penelitian ini. Oleh karena itu, vektor fitur dari setiap gambar berisi lima belas fitur GLCM efektif namun memerlukan waktu yang cukup lama dalam pemrosesan hasil ekstraksi fitur. Proses normalisasi GLCM sesuai dengan persamaan (2).

$$P(i, j) = \frac{V_{i,j}}{\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} V_{i,j}} \quad (2)$$

Berdasarkan persamaan (1), jumlah kolom ( $j$ ) dan baris ( $i$ ) sama dengan jumlah tingkat keabuan ( $G$ ) yang digunakan pada citra dan setiap elemen matriks  $V(i,j)$ , nilai sel ( $i,j$ ), dinormalisasi sebagai  $P(i, j)$ . Fitur-fitur yang diekstrak dari GLCM adalah sebagai berikut:

a) Mean

$$\mu_i = \sum_{i,j=0}^{G-1} i P(i,j) \quad (3)$$

$$\mu_j = \sum_{i,j=0}^{G-1} j P(i,j) \quad (4)$$

b) Varian

$$\sigma_i = \sum_{i,j=0}^{G-1} (i - \mu_i)^2 P(i,j) \quad (5)$$

$$\sigma_j = \sum_{i,j=0}^{G-1} (j - \mu_j)^2 P(i,j) \quad (6)$$

c) *Entropy*

$$\text{Entropy} = - \sum_{i,j=0}^{G-1} P(i,j) \log(P(i,j)) \quad (7)$$

Nilai entropy yang lebih tinggi diekstraksi dari adegan yang homogen, dan yang lebih rendah dari adegan yang tidak homogen.

d) *Dissimilarity*

$$\text{Dissimilarity} = \sum_{i,j=0}^{G-1} |i - j| P(i,j) \quad (8)$$

Dissimilarity mirip dengan kontras GLCM dan dikatakan tinggi jika daerah lokal memiliki kontras yang tinggi.

e) *Contrast*

$$\text{contrast} = \sum_{i,j=0}^{G-1} (i - j)^2 P(i,j) \quad (9)$$

Kontras atau variasi intensitas lokal mengukur jarak dari diagonal rata-rata matriks kookurensi tingkat keabuan dan semakin jauh semakin tinggi bobot yang diberikan pada  $P(i,j)$ , jadi kontras meningkat secara eksponensial ketika  $i-j$  meningkat.

f) *Inverse Difference Moment (Homogeneity)*

$$\text{IDM} = \sum_{i,j=0}^{G-1} \frac{P(i,j)}{1+(i-j)^2} \quad (10)$$

IDM mengukur kedekatan distribusi elemen GLCM ke diagonal utama. Semakin banyak konsentrasi di sepanjang diagonal utama di GLCM mengarah ke area yang lebih homogen dan karenanya nilai IDM lebih tinggi.

g) *Correlation*

Correlation digunakan untuk mengukur ketergantungan linier tingkat abu-abu antara piksel tetangga.

$$\text{correlation} = \sum_{i,j=0}^{G-1} \frac{(i - \mu_i)(j - \mu_j) P(i,j)}{\sigma_i \sigma_j} \quad (11)$$

Dalam penelitian sebelumnya menggunakan GLCM, beberapa fitur umum dan populer diekstraksi untuk melatih pengklasifikasi yang menghasilkan tingkat akurasi yang lebih rendah dibandingkan dengan metode ekstraktor fitur lainnya seperti *Discrete Wavelet Transform* (WT) atau *Principal Component Analysis* (PCA). Namun, dalam metode yang kami usulkan, mengekstraksi fitur-fitur canggih membuat klasifikasi yang kuat dengan pertumbuhan tingkat akurasi.

#### 2.4. Fitur HSV

Dalam pengolahan citra berwarna, ada berbagai model warna yang digunakan saat ini. Model RGB banyak digunakan dalam aplikasi berorientasi perangkat keras seperti monitor warna. Dalam model RGB, gambar diwakili oleh tiga komponen, satu untuk setiap warna primer - merah, hijau dan biru. Meskipun mata manusia sangat peka terhadap merah, hijau, dan biru, representasi RGB tidak cocok untuk menggambarkan citra berwarna dari sudut pandang persepsi manusia. Apalagi, sebuah warna tidak terbentuk begitu saja dari ketiga warna primer tersebut. Saat melihat objek berwarna, sistem visual manusia mencirikannya dengan kecerahan dan kromatisitasnya. Yang terakhir ini ditentukan oleh rona dan saturasi. Kecerahan adalah ukuran subjektif dari intensitas cahaya. HSV mewujudkan gagasan akromatik intensitas. Hue adalah atribut warna dan mewakili warna dominan. Saturasi adalah ekspresi kemurnian relatif atau tingkat di mana warna murni diencerkan oleh cahaya putih. Model HSV dimotivasi oleh sistem visual manusia. Dalam model HSV, komponen luminous (kecerahan) dipisahkan dari informasi pembawa warna (hue dan saturation) [11], [20]–[22]. Model warna HSV didefinisikan pada persamaan (11) berikut.

$$H = \begin{cases} 60\left(\frac{G-B}{\delta}\right) & \text{if } \text{MAX} = R \\ 60\left(\frac{B-R}{\delta} + 2\right) & \text{if } \text{MAX} = G \\ 60\left(\frac{R-G}{\delta} + 4\right) & \text{if } \text{MAX} = B \\ \text{not defined} & \text{if } \text{MAX} = 0 \end{cases} \quad (11)$$
$$S = \begin{cases} \frac{\delta}{\text{MAX}} & \text{if } \text{MAX} \neq 0 \\ 0 & \text{if } \text{MAX} = 0 \end{cases}$$
$$V = \text{MAX}$$

Dimana  $\delta = (\text{MAX} - \text{MIN})$ ,  $\text{MAX} = \max(R, G, B)$ , dan  $\text{MIN} = \min(R, G, B)$ . Perhatikan bahwa nilai R, G, B pada Persamaan (1) diskalakan ke  $[0, 1]$ . Untuk membatasi H dalam kisaran  $[0, 360]$  seperti pada persamaan (12).

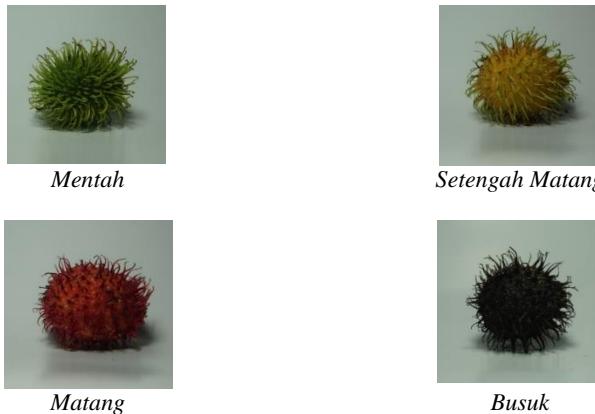
$$H = H + 360, \text{ if } H < 0 \quad (12)$$

Lebih alami bagi sistem visual manusia untuk menggambarkan gambar berwarna dengan model HSV daripada dengan model RGB. Secara intuitif, fitur yang diekstraksi dalam ruang warna HSV dapat menangkap karakteristik grafis komputer yang berbeda dengan lebih baik. [23] Misalnya, grafik komputer lebih halus warnanya daripada gambar fotografi di area tekstur. Lebih sedikit warna yang terkandung dalam grafik komputer. Intensitas grafik komputer mengungkapkan karakteristik tepi dan bayangan yang berbeda. Perbedaan antara grafik komputer dan gambar fotografi ini paling baik dijelaskan dengan memisahkan intensitas dari informasi kromatik, katakanlah, rona dan saturasi. Terinspirasi oleh cara sistem visual manusia melihat objek warna, kami mengusulkan untuk membangun fitur dari ruang warna HSV. Untuk tujuan perbandingan kinerja, fitur juga diekstraksi dalam ruang warna RGB. Seperti yang ditunjukkan pada bagian selanjutnya, fitur HSV memiliki kinerja klasifikasi yang lebih baik daripada fitur RGB.

### 3. INSTRUMEN PENELITIAN

#### 3.1. Dataset Penelitian

Klasifikasi tingkat kematangan buah rambutan dilakukan dengan dua pendekatan, yaitu machine learning dan transfer learning. Tahap kematangan didefinisikan sesuai dengan aspek visual warna kulit, diilustrasikan pada Tabel 1 dan Gambar 3 dimana telah diilustrasikan sampel pada setiap level kematangan buah.



Gambar 3. Sampel Dataset Buah Rambutan Pada Masing-Masing Level Kematangan

Tabel 1. Level kematangan buah Rambutan.

Level kematangan	Keterangan
Mentah	Kulit hijau tanpa garis kuning
Setengah matang	Kulit kuning dan mungkin beberapa helai rambut berwarna merah
Matang	Seluruh kulit berwarna merah merata
Busuk	Kulit berwarna coklat atau hitam

Buah rambutan segar dikumpulkan dari kebun dan diletakkan di atas kertas putih satu per satu untuk diabadikan. Citra diambil menggunakan kamera Smartphone dengan resolusi 13 Megapiksel dalam cahaya alami hari itu, antara pukul 10 pagi hingga 3 sore. Proses akuisisi citra dilakukan di dalam ruangan dengan bantuan stand smartphone holding untuk menjaga jarak 35cm. Diperhatikan bahwa; ruangan memiliki cahaya alami yang tepat dan tidak memiliki cahaya langsung yang dapat menyebabkan pantulan dan bayangan pada latar belakang. Selain itu, latar belakang putih menekankan kejelasan dan menghilangkan hambatan visual dan kecacauan. Semua gambar diubah ukurannya ke dimensi  $227 \times 227 \times 3$ . Citra buah pepaya dikategorikan menjadi tiga kelas yaitu belum matang, matang sebagian dan matang sesuai karakteristik visual yang diilustrasikan pada Tabel 1. Semua sampel juga diperiksa silang dengan masing-masing penampang melintang dan membujur. Total 100 sampel dengan 4 kelas berbeda sesuai Tabel 1. Jumlah sampel dibagi untuk pelatihan, dan pengujian masing-masing sebesar 60% dan 40%.

#### 3.2. Teknik Analisa Hasil

Teknik analisa hasil yang digunakan dalam penelitian ini yaitu perhitungan akurasi sesuai persamaan (13).

$$Akurasi = \frac{\text{jumlah data yang bernilai benar}}{\text{jumlah keseluruhan data}} \times 100\% \quad (13)$$

## 4. HASIL DAN PEMBAHASAN

### 4.1. Ekstraksi Fitur

Dalam proses ekstraksi fitur metode yang digunakan yaitu dengan Metode GLCM (*Gray Level Coocurrence Matrix*) yang menghasilkan nilai kontras, korelasi, energi, dan

homogenitas dari suatu citra. Sebagai contoh berikut merupakan contoh perhitungan dari proses GLCM dengan menggunakan citra berukuran 3-bit seperti pada Gambar 4.

4	5	3
6	1	4
1	4	5

Gambar 4. Matriks 3x3 piksel

Hitung fitur ekstraksi fitur tekstur dengan jarak 1 dan  $\theta = 0^\circ$  ( $[0 \ 1]$ ) untuk mencari nilai kontras, korelasi, energi, dan homogenitas seperti pada Gambar 5.

$i/j$	0	1	2	3	4	5	6
0	0	0	0	0	0	0	0
1	0	0	0	0	2	0	0
2	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0
4	0	0	0	0	0	2	0
5	0	0	0	1	0	0	0
6	0	1	0	0	0	0	0

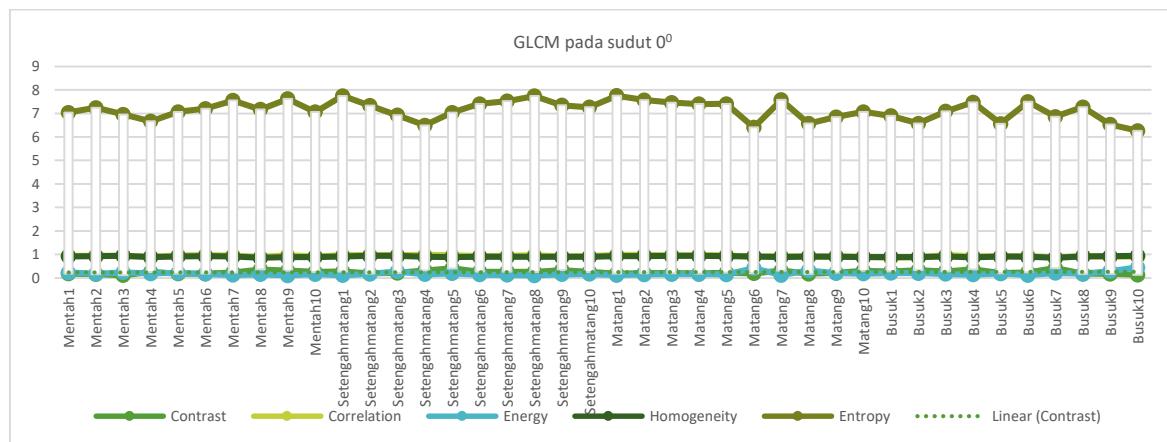
GLCM sebelum normalisasi

$i/j$	0	1	2	3	4	5	6
0	0	0	0	0	0	0	0
1	0	0	0	0	0	$2/6$	0
2	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0
4	0	0	0	0	0	0	$2/6$
5	0	0	0	$1/6$	0	0	0
6	0	$1/6$	0	0	0	0	0

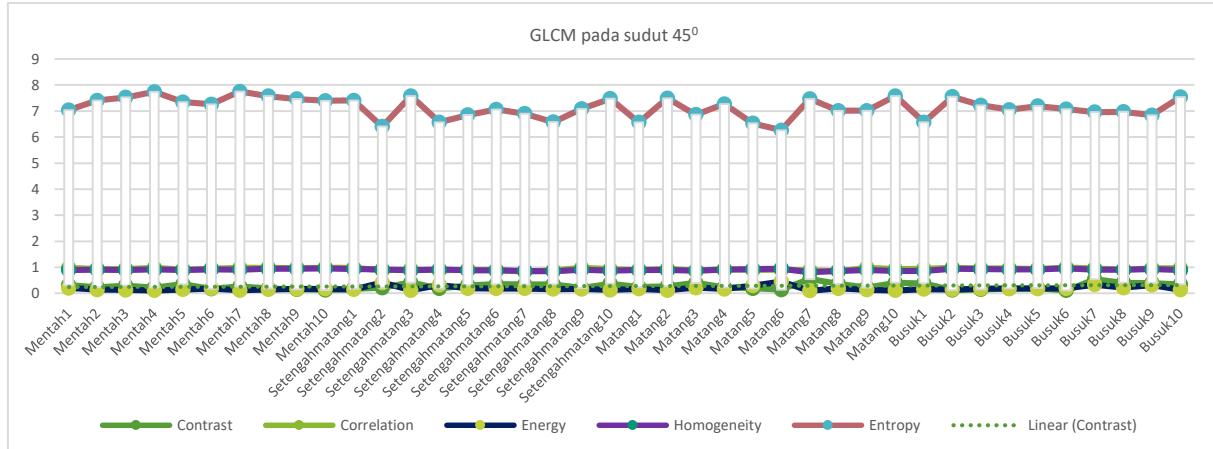
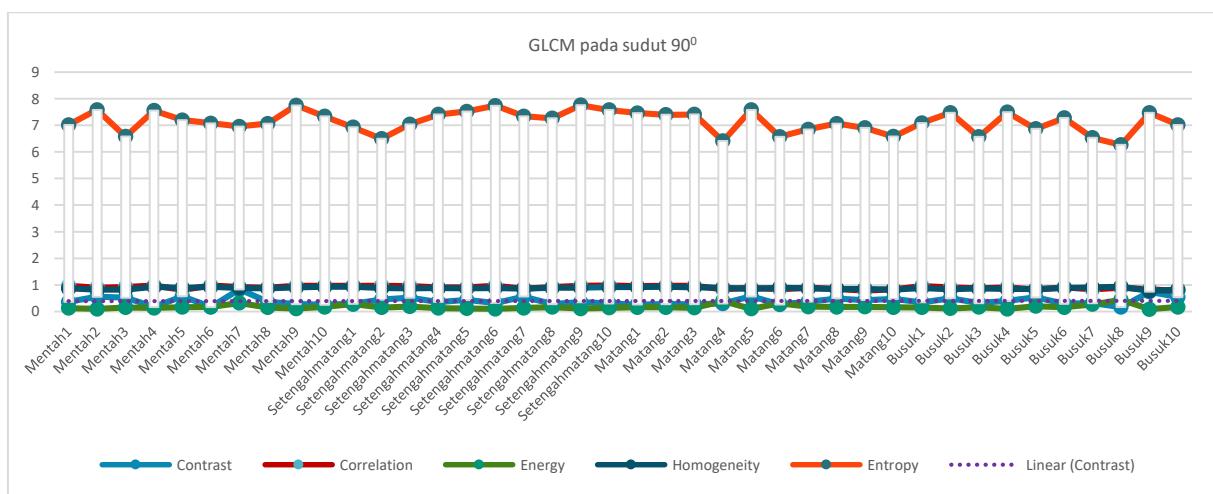
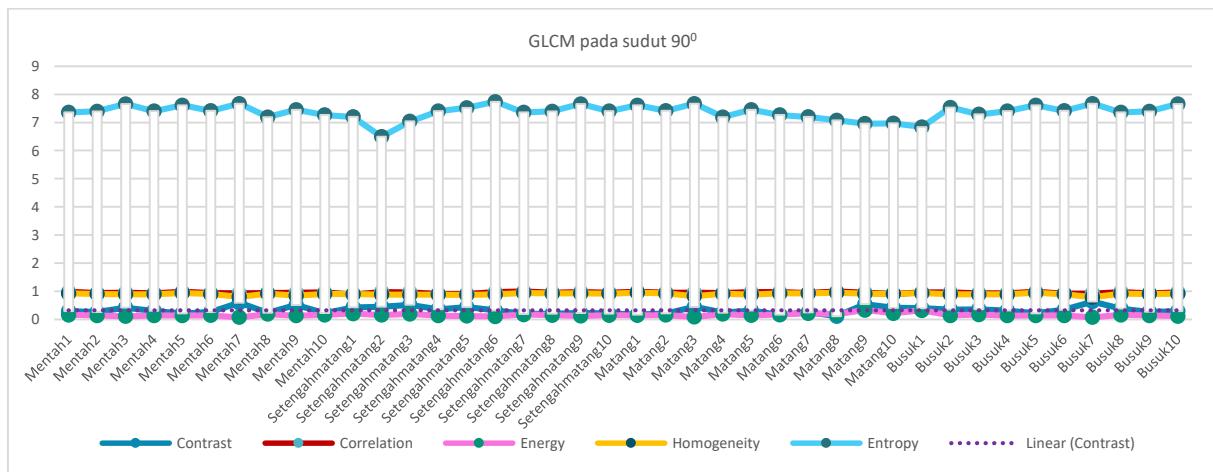
GLCM setelah normalisasi

Gambar 5. Proses Normalisasi Citra GLCM

Setelah mengetahui nilai kontas, korelasi, energi dan homogenitas yang dihasilkan oleh metode GLCM sesuai Gambar 6, kemudian nilai tersebut digunakan untuk perhitungan proses selanjutnya pada fitur ekstraksi warna HSV. Setelah semua data citra (data *trainning* dan data *testing*) telah di ekstraksi fitur tekturnya, langkah selanjutnya ialah mengekstraksi fitur warna dengan menggunakan HSV. Gambar 6 hingga Gambar 9 merupakan nilai GLCM dari hasil percobaan menggunakan 40 citra testing pada nilai K=1.



Gambar 6. Nilai GLCM pada Sudut 0°

Gambar 7. Nilai GLCM pada sudut  $45^0$ Gambar 8. Nilai GLCM pada sudut  $90^0$ Gambar 9. Nilai GLCM pada Sudut  $135^0$ 

#### 4.2. Klasifikasi K-NN

Pada percobaan yang telah dilakukan menggunakan  $K=1,3,5,7,9,11$ , dan 13 menggunakan GLCM pada sudut  $0^0$ ,  $45^0$ ,  $90^0$ ,  $135^0$  akurasi yang dihasilkan diilustrasikan pada Tabel 2 dan Gambar 9 berikut ini. Menentukan jarak terdekat antara data testing dan data training, semakin dekat jarak dan nya maka data tersebut masuk kedalam tingkat kematangannya.

Tabel 2. Perhitungan Jarak Menggunakan Euclidean Distance

Nama	Kontras	Korelasi	Energi	Hom	R	G	B	Kelas	Jarak
DTRAIN 1 (1).jpg	0,899	-0,15	-1,409	-0,362	1,239	6,926	5,912	Mentah	0,2092
DTRAIN 1 (2).jpg	0,797	-0,122	-1,346	-0,288	1,019	6,118	4,922	Mentah	0,2239
DTRAIN 2 (1).jpg	0,712	-0,293	-0,134	-0,267	6,038	7,146	6,797	Setengah Matang	0,0874
DTRAIN 2 (2).jpg	0,808	-0,2845	-0,55	-0,284	5,762	6,02	6,752	Setengah Matang	0,0185
DTRAIN 3 (1).jpg	1,004	-0,14075	-1,509	-0,315	5,494	-6,956	4,849	Matang	0,2438
DTRAIN 3 (2).jpg	1,044	-0,143	-1,476	-0,328	5,371	-6,069	5,957	Matang	0,2378
DTRAIN 4 (1).jpg	0,791	-0,08	-0,949	-0,192	1,007	6,243	16,237	Busuk	0,1426
DTRAIN 4 (2).jpg	0,716	-0,087	-0,076	-0,168	-5,055	-0,102	9,369	Busuk	0,1580

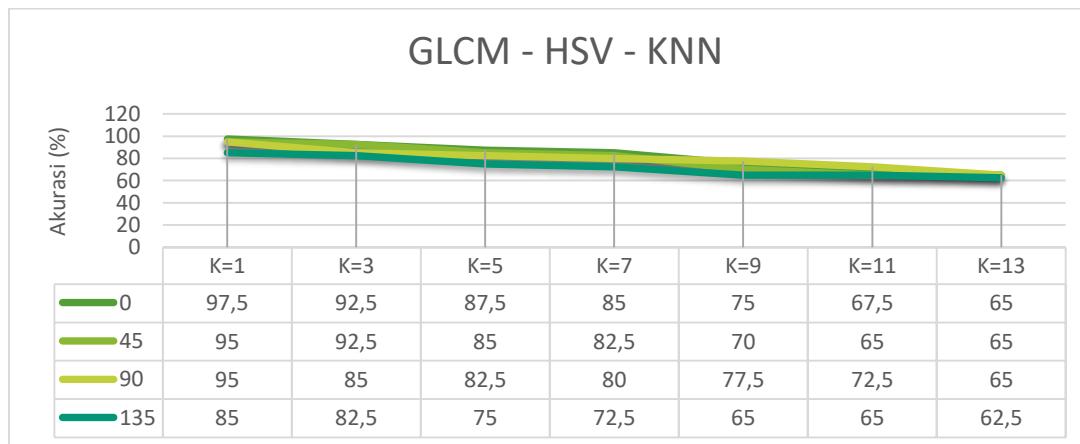
Untuk memperjelas hasil klasifikasi, pada Tabel 3 dapat dilihat mengenai kesamaan antara citra aktual dan citra hasil klasifikasi.

Tabel 3. Kesamaan Citra Actual dan Citra Hasil Klasifikasi pada K=1 dan jaran dari 1 sampai 9

Nama Citra	d=1		d=2		d=3		d=4		d=5		d=6		d=7		d=8		d=9	
	A	K	A	K	A	K	A	K	A	K	A	K	A	K	A	K	A	K
TST 1 (1)	Me	Me	Me															
TST 1 (2)	Me	Me	Me															
TST 1 (3)	Me	Me	Me															
TST 1 (4)	Me	SM	Me															
TST 1 (5)	Me	Me	Me															
TST 1 (6)	Me	Me	Me															
TST 1 (7)	Me	Me	Me															
TST 1 (8)	Me	Me	Me															
TST 1 (9)	Me	Me	Me															
TST 1 (10)	Me	Me	Me															
TST 1 (11)	Me	Me	Me															
TST 1 (12)	Me	Me	Me															
TST 1 (13)	Me	Me	Me															
TST 1 (14)	Me	Me	Me															
TST 1 (15)	Me	Me	Me															
TST 1 (16)	Me	Me	Me															
TST 1 (17)	Me	Me	Me															
TST 1 (18)	Me	Me	Me															
TST 1 (19)	Me	Me	Me															
TST 1 (20)	Me	Me	Me															
TST 2 (1)	SM	SM	SM															
TST 2 (2)	SM	SM	SM															
TST 2 (3)	SM	SM	SM															
TST 2 (4)	SM	SM	SM															
TST 2 (5)	SM	SM	SM															
TST 2 (6)	SM	SM	SM															
TST 2 (7)	SM	SM	SM															
TST 2 (8)	SM	SM	SM															
TST 2 (9)	SM	SM	SM															
TST 2 (10)	SM	SM	SM															
TST 2 (11)	SM	SM	SM															
TST 2 (12)	SM	SM	SM															
TST 2 (13)	SM	SM	SM															
TST 2 (14)	SM	SM	SM															
TST 2 (15)	SM	SM	SM															
TST 2 (16)	SM	SM	SM															
TST 2 (17)	SM	SM	SM															
TST 2 (18)	SM	SM	SM															
TST 2 (19)	SM	SM	SM															
TST 2 (20)	SM	SM	SM															
TST 3 (1)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (2)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (3)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (4)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (5)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (6)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (7)	M	M	M	M	M	B	M	B	M	B	M	B	M	B	M	B	B	
TST 3 (8)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	
TST 3 (9)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	

TST 3 (10)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (11)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (12)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (13)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (14)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (15)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (16)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (17)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (18)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (19)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 3 (20)	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M	M
TST 4 (1)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (2)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (3)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (4)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (5)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (6)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (7)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (8)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (9)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (10)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (11)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (12)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (13)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (14)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (15)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (16)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (17)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (18)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (19)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B
TST 4 (20)	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B

Berdasarkan Tabel 3, dapat dilihat pada jarak  $d=1$  dan  $d=2$  akurasi yang dihasilkan yaitu sama 98,5% sedangkan pada  $d=3$ ,  $d=4$ , dan  $d=5$  menghasilkan 97,5%. Pada  $d=6$ ,  $d=7$ ,  $d=8$  dan  $d=9$  sama-sama menghasilkan akurasi 96,25%. Dalam penelitian ini telah di data hasil percobaan menggunakan  $d=1$  hingga  $d=9$  pada  $K=1$ , 3, 5, 7, dan 9. Untuk mengtahui akurasi dari hasil klasifikasi dapat di lihat pada Gambar 10.



Gambar 10: Nilai GLCM pada sudut  $135^0$

## 5. KESIMPULAN

Proses klasifikasi citra buah rambutan dapat diklasifikasikan menggunakan K-NN dan fitur ekstraksi GLCM. Akurasi yang dihasilkan cukup tinggi. Pada  $K=13$  merupakan akurasi terendah dengan nilai 62,5%, sedangkan pada  $K=1$  merupakan akurasi tertinggi yaitu 97,5%. Pada  $K=3$  dan  $K=5$  hingga  $K=7$ , nilai akurasi masih cukup tinggi dengan rata-rata hingga 80%. Penggunaan fitur ekstraksi tentu memberikan pengaruh nilai akurasi yang lebih optimal dibandingkan hanya dengan menggunakan K-NN saja. Pada penelitian selanjutnya, sebaiknya dapat

diimplementasikan fitur ekstraksi warna misal MeanRGB atau  $L^*a^*b$ . Sebagai algoritma fitur ekstraksi pembanding dapat pula digunakan Linear Binary Pattern (LBP) atau Principal Component Analysis (PCA). Untuk algoritma klasifikasi dapat diimplementasikan machine learning atau deep learning misalnya Support Vector Machine (SVM) atau Convolutional Neural Network (CNN) sehingga akurasi lebih optimal.

## DAFTAR PUSTAKA

- [1] Irwan Falud Sen, “Deteksi Kematangan Buah Rambutan Berdasarkan Warna Menggunakan Metode Discrete Cosine Transform,” vol. 2, no. 1, pp. 40–47, 2018.
- [2] Y. J. Wong, S. K. Arumugasamy, C. H. Chung, A. Selvarajoo, and V. Sethu, “Comparative study of artificial neural network (ANN), adaptive neuro-fuzzy inference system (ANFIS) and multiple linear regression (MLR) for modeling of Cu (II) adsorption from aqueous solution using biochar derived from rambutan (*Nephelium lappaceum*) pee,” *Environ. Monit. Assess.*, vol. 192, no. 7, p. 439, Jul. 2020.
- [3] C. Kumar, S. Chauhan, R. N. Alla, and H. Mounica gurram, “Classifications of citrus fruit using image processing -GLCM parameters,” in *2015 International Conference on Communications and Signal Processing (ICCSP)*, 2015, pp. 1743–1747.
- [4] L. Fu et al., “Fast and accurate detection of kiwifruit in orchard using improved YOLOv3-tiny model,” *Precis. Agric.*, no. 0123456789, 2020.
- [5] C. Paramita, E. Hari Rachmawanto, C. Atika Sari, and D. R. Ignatius Moses Setiadi, “Klasifikasi Jeruk Nipis Terhadap Tingkat Kematangan Buah Berdasarkan Fitur Warna Menggunakan K-Nearest Neighbor,” *J. Inform. J. Pengemb. IT*, vol. 4, no. 1, pp. 1–6, 2019.
- [6] C. E. Cabrera Ardila, L. Alberto Ramirez, and F. A. Prieto Ortiz, “Spectral analysis for the early detection of anthracnose in fruits of Sugar Mango (*Mangifera indica*),” *Comput. Electron. Agric.*, vol. 173, no. March, p. 105357, Jun. 2020.
- [7] K. Komal and Sonia, “GLCM Algorithm and SVM Classification Method for Orange Fruit Quality Assessment,” *Int. J. Eng. Res. Technol.*, vol. 8, no. 09, pp. 697–703, 2019.
- [8] K. Warman, L. A. Harahap, and P. Munir, “Identifikasi Kematangan Buah Jeruk Dengan Teknik Jaringan Syaraf Tiruan,” *J. Rekayasa Pangan dan Pert*, vol. 3, no. 2, pp. 248–253, 2015.
- [9] D. Nursantika and F. R. Umbara, “Pengenalan Citra Buah Manggis Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation,” in Seminar Nasional Telekomunikasi dan Informatika, 2016, no. Selisik, pp. 182–184.
- [10] Z.-L. He et al., “A method of green litchi recognition in natural environment based on improved LDA classifier,” *Comput. Electron. Agric.*, vol. 140, pp. 159–167, Aug. 2017.
- [11] O. R. Indriani, E. J. Kusuma, C. A. Sari, E. H. Rachmawanto, and D. R. I. M. Setiadi, “Tomatoes Classification Using K-NN Based on GLCM and HSV Color Space,” in *International Conference on Innovative and Creative Information Technology (ICITech)*, 2017, pp. 1–6.
- [12] A. Zubair and A. R. Muslih, “Identifikasi jamur menggunakan metode k-nearest neighbor dengan ekstraksi ciri morfologi,” in *Seminar Nasional Sistem Informasi*, 2017, no. September, pp. 965–972.
- [13] Y. Chen et al., “Variety identification of orchids using Fourier transform infrared spectroscopy combined with stacked sparse auto-encoder,” *Molecules*, vol. 24, no. 13, 2019.
- [14] E. Hari Rachmawanto, G. Rambu Anarqi, D. R. I. Moses Setiadi, and C. Atika Sari, “Handwriting Recognition Using Eccentricity and Metric Feature Extraction Based on K-Nearest Neighbors,” *Proc. - 2018 Int. Semin. Appl. Technol. Inf. Commun. Creat. Technol. Hum. Life, iSemantic 2018*, pp. 411–416, 2018.
- [15] I. U. W. Mulyono et al., “Parijoto Fruits Classification using K-Nearest Neighbor Based on Gray Level Co-Occurrence Matrix Texture Extraction,” *J. Phys. Conf. Ser.*, vol. 1501, no. 1, 2020.

- [16] A. A. Chandini and U. Maheswari B., “Improved Quality Detection Technique for Fruits Using GLCM and MultiClass SVM,” in *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2018, pp. 150–155.
- [17] S. Jana, S. Basak, and R. Parekh, “Automatic fruit recognition from natural images using color and texture features,” in *2017 Devices for Integrated Circuit (DevIC)*, 2017, pp. 620–624.
- [18] S. A. Banday and A. H. Mir, “Statistical textural feature and deformable model based brain tumor segmentation and volume estimation,” *Multimed. Tools Appl.*, vol. 76, no. 3, pp. 3809–3828, 2017.
- [19] E. Hossain, M. F. Hossain, and M. A. Rahaman, “A Color and Texture Based Approach for the Detection and Classification of Plant Leaf Disease Using KNN Classifier,” *2nd Int. Conf. Electr. Comput. Commun. Eng. ECCE 2019*, pp. 1–6, 2019.
- [20] F. Ferreira Lima dos Santos, J. Rosas, R. Martins, G. Araújo, L. Viana, and J. Gonçalves, “Quality assessment of coffee beans through computer vision and machine learning algorithms,” *Coffee Sci.*, vol. 15, no. 1, pp. 1–9, 2020.
- [21] P. N. Andono, E. H. Rachmawanto, N. S. Herman, and K. Kondo, “Orchid types classification using supervised learning algorithm based on feature and color extraction,” *Bull. Electr. Eng. Informatics*, vol. 10, no. 5, pp. 2530–2538, Oct. 2021.
- [22] S. Sanjaya, M. L. Pura, S. K. Gusti, F. Yanto, and F. Syafria, “K-Nearest Neighbor for Classification of Tomato Maturity Level Based on Hue, Saturation, and Value Colors,” *Indones. J. Artif. Intell. Data Min.*, vol. 2, no. 2, p. 101, Nov. 2019.
- [23] A. Susanto, Z. H. Dewantoro, C. A. Sari, D. R. I. M. Setiadi, E. H. Rachmawanto, and I. U. W. Mulyono, “Shallot Quality Classification using HSV Color Models and Size Identification based on Naive Bayes Classifier,” *J. Phys. Conf. Ser.*, vol. 1577, no. 1, 2020.