

## Klasifikasi Citra Biji Arbila di Kabupaten Kupang menggunakan *k*-Nearest Neighbor berdasarkan fitur Warna dan Tekstur

### *Classification of Arbila Seed Images in Kupang Regency using k-Nearest Neighbor based on Color and Texture Features*

Allen Miquel Dwitala<sup>1</sup>, Adriana Fanggalda<sup>\*1</sup>, Yulianto Triwahyuadi Polly<sup>1</sup>, Bernadete B. Koten<sup>2</sup>

<sup>1</sup> Program Studi Ilmu Komputer, Fakultas Sains dan Teknik, Universitas Nusa Cendana, Jl. Adi Sucipto Penfui, Kupang, Indonesia

<sup>2</sup> Jurusan Peternakan, Politeknik Pertanian Negeri Kupang, Jl. Prof. Dr. Herman Yohanes Lasiana, Kupang, Indonesia  
Email\* : adrianafanggalda@staf.undana.ac.id

**Abstrak** - Arbila (*Phaseolus lunatus L.*) adalah legum pangan dari keluarga *Fabaceae* (*Leguminosae*) yang dibedakan menjadi dua kategori: Arbila yang dapat dikonsumsi oleh manusia dan ternak, serta Arbila yang mengandung asam sianida berbahaya. Variasi warna dan tekstur biji Arbila dapat menyebabkan kesalahan dalam pemilahan manual oleh masyarakat. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model yang dapat membantu identifikasi jenis biji Arbila. Dalam penelitian ini, digunakan tiga fitur warna berdasarkan model HSV (*Hue, Saturation, dan Value*) dan empat fitur tekstur berdasarkan GLCM (*Gray Level Co-Occurrence Matrix*) sebagai parameter input untuk klasifikasi. Metode yang diterapkan adalah *k*-NN (*k-Nearest Neighbor*) dengan total 600 citra dari 10 jenis biji Arbila. Eksperimen dilakukan dengan berbagai nilai *k* (1, 3, 5, 7, dan 9) serta menerapkan *10-fold Cross-Validation* untuk menguji performa sistem. Hasil penelitian menunjukkan bahwa nilai akurasi maksimum rata-rata yang dicapai adalah 89,33% pada nilai *k* = 1, sedangkan akurasi terendah adalah 79,33% pada *k* = 9. Dengan demikian, disimpulkan bahwa model terbaik untuk klasifikasi citra biji Arbila di Kabupaten Kupang adalah *k*-NN dengan *k* = 1. Model ini berpotensi untuk dikembangkan menjadi sistem klasifikasi yang dapat membantu masyarakat dalam pemilihan biji Arbila yang tepat, sehingga meningkatkan produksi ternak dan gizi masyarakat.

**Kata kunci** : Biji Arbila, *k*-Nearest Neighbor, GLCM, *Hue Saturation Value*, *K-Fold-Cross-Validation*.

**Abstract** - Arbila (*Phaseolus lunatus L.*) is a food legume belonging to the *Fabaceae* (*Leguminosae*) family, which can be classified into two categories: Arbila that is safe for human and animal consumption, and Arbila that contains harmful concentrations of cyanogenic acid. The variations in color and texture of Arbila seeds can lead to errors in manual sorting by the community. Therefore, this study aims to develop a model that assists in the identification of Arbila seed types. In this research, three color features based on the HSV (*Hue, Saturation, and Value*) model and four texture features derived from the GLCM (*Gray Level Co-Occurrence Matrix*) were utilized as input parameters for classification. The method employed is *k*-NN (*k-Nearest Neighbor*), using a total of 600 images from 10 different types of Arbila seeds. Experiments were conducted with varying values of *k* (1, 3, 5, 7, and 9) and applied *10-fold Cross-Validation* to evaluate the system's performance. The results indicate that the maximum average accuracy achieved was 89.33% at *k* = 1, while the lowest accuracy was 79.33% at *k* = 9. Consequently, it is concluded that the best model for classifying Arbila seed images in Kupang Regency is *k*-NN with *k* = 1. This model has the potential to be developed into a classification system that can aid the community in selecting the appropriate Arbila seeds, thereby enhancing livestock production and improving community nutrition.

**Keywords** : Arbila seeds, *k*-Nearest Neighbor, GLCM, *Hue Saturation Value*, *K-Fold-Cross-Validation*.

## I. PENDAHULUAN

Tanaman Legum Arbila (*Phaseolus lunatus L.*) merupakan sumber daya alam yang penting bagi masyarakat, khususnya di Kabupaten Kupang.

Klasifikasi biji Arbila sangat penting karena dapat membantu petani dan masyarakat lokal dalam memilih jenis biji yang tepat untuk keperluan konsumsi dan pakan ternak. Dengan

mengembangkan sistem klasifikasi yang akurat, maka dapat meningkatkan kualitas pemilihan biji yang berdampak positif terhadap produktivitas pertanian lokal dan kesehatan masyarakat. Penelitian ini bertujuan untuk mengatasi tantangan dalam identifikasi biji Arbila, terutama mengingat kesulitan yang dihadapi manusia dalam membedakan varietas yang serupa secara visual [1][2].

Klasifikasi citra menggunakan fitur warna dan tekstur telah diterapkan dalam berbagai penelitian. Sebagian besar studi sebelumnya memiliki kelemahan dalam hal akurasi dan efisiensi pengolahan data. Metode *k-Nearest Neighbor* (*k*-NN) dikenal sebagai teknik yang sederhana namun efektif dalam klasifikasi, karena mampu membandingkan jarak antara data yang diuji dengan data latih. Penelitian terdahulu, seperti yang dilakukan oleh Sujaini (2019), menunjukkan bahwa *k*-NN memiliki akurasi 92,1%, yang lebih baik dibandingkan dengan metode lain seperti *Support Vector Machine* (SVM) yang mencapai 85,4% dan *Random Forest* (RF) yang hanya 69,4% [3]. Penelitian oleh Wijaya dan Ridwan juga menunjukkan bahwa penggunaan kombinasi fitur warna dan tekstur dalam klasifikasi dapat mencapai akurasi rata-rata 94% [4]. Selain itu, penelitian yang dilakukan oleh Jerandu dan rekannya menunjukkan akurasi 90% dalam klasifikasi kesegaran ikan dengan menggunakan fitur warna [5], yang menunjukkan relevansi metode ini dalam konteks klasifikasi yang berbeda. Namun, tidak semua penelitian mengkaji potensi kombinasi antara fitur warna dan tekstur secara mendalam, sehingga menjadi peluang inovasi dalam studi ini.

Meskipun ada penelitian yang relevan, masih terdapat kesenjangan dalam penggunaan metode yang menggabungkan ekstraksi fitur warna dan tekstur secara simultan dalam klasifikasi biji Arbila. Penelitian ini untuk mengisi celah tersebut dengan menggunakan model HSV (*Hue, Saturation, Value*) untuk fitur warna dan GLCM (*Gray Level Co-Occurrence Matrix*) untuk fitur tekstur. Penelitian ini terinspirasi oleh studi sebelumnya yang dilakukan oleh Sari dan Sari (2022), yang menunjukkan bahwa kombinasi fitur dapat menghasilkan akurasi hingga 96% [6]. Penelitian lain oleh Pah dan koleganya juga menggunakan pendekatan serupa dan berhasil

mencapai rata-rata akurasi 98,82% dalam klasifikasi berbagai jenis apel [7]. Dengan demikian, penelitian ini tidak hanya berkontribusi dalam klasifikasi biji Arbila, tetapi juga memberikan wawasan baru tentang efektivitas kombinasi kedua metode ini dalam konteks yang berbeda. Penelitian oleh Srg dan rekan juga memperlihatkan bahwa klasifikasi citra menggunakan teknik GLCM untuk ekstraksi fitur tekstur dapat sangat bermanfaat dalam mendeteksi perbedaan yang halus pada citra [8], sehingga semakin memperkuat pentingnya metode ini dalam penelitian kami.

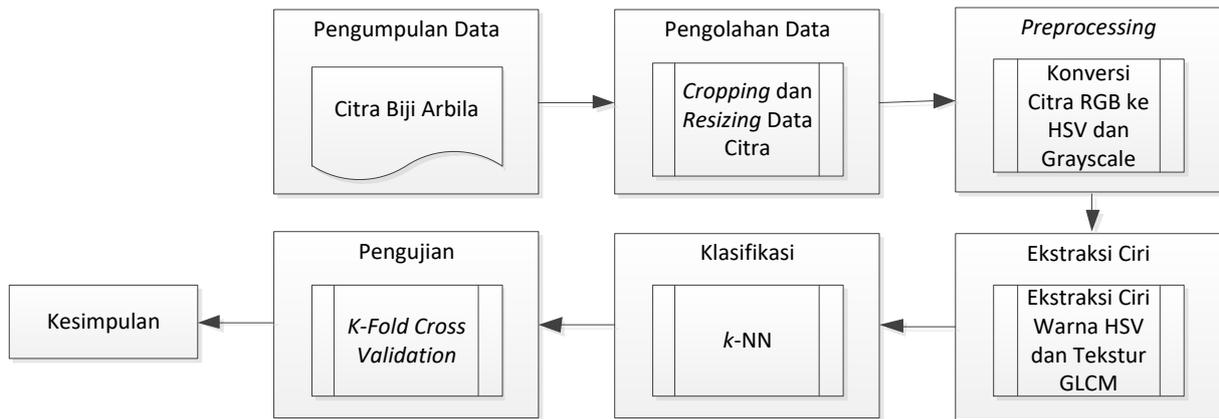
Dalam penelitian ini, metode *k*-NN diimplementasikan untuk mengklasifikasikan biji Arbila berdasarkan fitur warna dan tekstur. Pemanfaatan ekstraksi fitur berdasarkan model warna HSV dan tekstur GLCM, terinspirasi oleh penelitian yang menunjukkan keberhasilan metode ini dalam klasifikasi citra, seperti yang dilakukan oleh Suryani dan rekan-rekannya yang mencapai akurasi 94% [9], serta penelitian Jerandu dan rekan-rekannya yang memperoleh akurasi 90% [5]. Eksperimen ini dirancang untuk mengevaluasi akurasi klasifikasi dengan memanfaatkan *dataset* yang terdiri dari citra biji Arbila. Harapan temuan dari penelitian ini dapat memberikan manfaat signifikan bagi masyarakat, terutama dalam proses pemilihan biji yang sesuai dengan kebutuhan mereka.

## II. METODOLOGI

Langkah-langkah yang diperlukan untuk melakukan klasifikasi citra biji Arbila meliputi proses pengumpulan data, pengolahan data, tahapan *preprocessing*, ekstraksi fitur, proses klasifikasi, pengujian, dan menyimpulkan hasil, sebagaimana yang tergambar dalam **Gambar 1**.

### A. Pengumpulan Data

Pengumpulan data dilaksanakan secara teliti dan hati-hati melalui pengambilan gambar dari sepuluh jenis biji Arbila yang berbeda yang dibudidayakan di Politeknik Pertanian Negeri Kupang. Jenis-jenis biji Arbila tersebut mencakup *koto bona*, *koto bu'u*, *koto ika*, *koto mina*, *koto paratrao muti kot me'e*, *koto paratrao muti kot metan*, *koto sisi*, *koto usif*, beracun 1 (berwarna coklat tanpa corak), dan beracun 2 (berwarna coklat dengan corak hitam).



Gambar 1. Tahapan Penelitian

Setiap jenis biji Arbila dikumpulkan sebanyak 20 biji. Data citra diambil menggunakan kamera *smartphone iPhone 6s Plus*. Setiap biji Arbila difoto sebanyak tiga kali, dengan masing-masing pengambilan gambar dilakukan dari tiga sudut yang berbeda, yaitu  $45^{\circ}$ ,  $90^{\circ}$ , dan  $135^{\circ}$  derajat dari sisi atas biji Arbila. Sehingga, total terdapat 600 data citra yang diterapkan dalam penelitian ini. Dalam proses pengambilan gambar, jarak antara biji Arbila dan kamera diatur sekitar 8 hingga 10 cm, karena pengambilan gambar yang terlalu jauh akan menghasilkan objek yang terlalu kecil, sementara jarak yang terlalu dekat dapat mengakibatkan gambar menjadi buram atau tidak jelas. Selain itu, hilum dari biji Arbila ditempatkan di sebelah kanan untuk memudahkan pengambilan gambar dari seluruh biji Arbila. Jenis biji Arbila yang digunakan dalam penelitian ini bisa dilihat pada Gambar 2.

### B. Pengolahan Data

Pengolahan data dilakukan melalui pemilihan jenis data citra yang tidak memiliki kecacatan untuk digunakan dalam penelitian, dan untuk gambar dengan kecacatan seperti gambar buram atau terdapat noda pada gambar, akan dibuang.

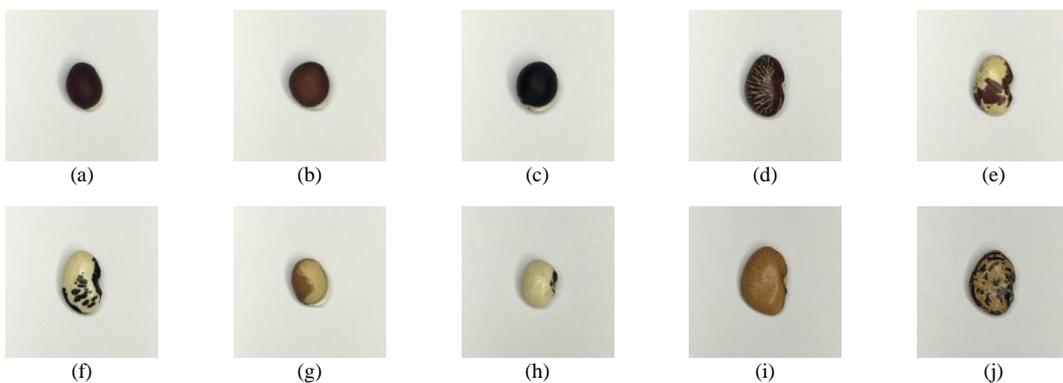
Selanjutnya, gambar dipotong secara manual dari ukuran aslinya, yaitu  $3024 \times 4032$  piksel, menjadi  $1250 \times 1250$  piksel. Kemudian, akan dilakukan proses *resizing* terhadap data citra menjadi ukuran  $250 \times 250$  piksel. Pada setiap data, terdapat atribut yang meliputi *correlation*, *homogeneity*, *H*, *S*, *V*, *energy*, *contrast*, dan kelas. Gambar 3 menunjukkan contoh data citra sebelum dan setelah dilakukan proses *resizing*.

### C. Preprocessing

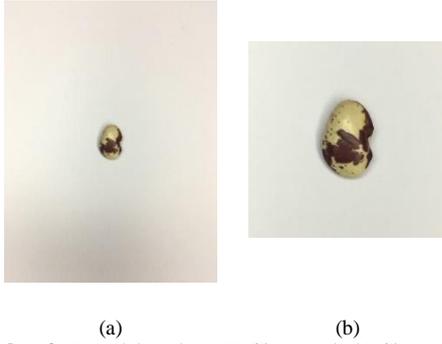
Dalam konteks penelitian ini, terdapat dua tahapan *preprocessing* yang dilakukan, yaitu konversi citra model warna RGB menjadi model warna HSV serta menjadi citra grayscale.

#### 1) Konversi citra RGB ke HSV

Dalam terminologi yang berkaitan, model warna HSV didefinisikan sebagai berikut: *Hue* mengindikasikan warna sebenarnya dan memiliki rentang nilai dari 0 sampai 360 derajat, *Saturation* menggambarkan tingkat kemurnian warna dan dinyatakan dalam persentase mulai dari 0% hingga 100%, sementara *Value* menggambarkan tingkat kecerahan warna dengan rentang nilai dari 0% hingga 100% [10].



Gambar 2. Contoh citra biji Arbila di Kota Kupang: (a) Koto Bona, (b) Koto Bu'u, (c) Koto Ika, (d) Koto Mina, (e) Koto Paratrao Muti Kot Me'e, (f) Kot Paratrao Muti Kot Metan, (g) Koto Sisi, (h) Koto Usif, (i) Beracun 1, (j) Beracun 2



Gambar 3. Pengolahan data: (a) Citra awal, (b) Citra setelah dipotong dan *resizing*

Langkah-langkah dalam proses konversi warna model warna RGB menjadi model warna HSV diuraikan dalam persamaan (1) hingga persamaan (8) [11].

$$r = \frac{R}{255} \quad (1)$$

$$g = \frac{G}{255} \quad (2)$$

$$b = \frac{B}{255} \quad (3)$$

$$V = \max(r, g, b) \quad (4)$$

$$Cmin = \min(r, g, b) \quad (5)$$

$$\Delta = V - Cmin \quad (6)$$

$$S = \begin{cases} 0, & \text{jika } Cmax = 0 \\ \frac{\Delta}{V}, & \text{jika } Cmax \neq 0 \end{cases} \quad (7)$$

$$H = \begin{cases} 60^\circ \times \left(\frac{g-b}{\Delta} \bmod 6\right), & V = r \\ 60^\circ \times \left(\frac{b-r}{\Delta} + 2\right), & V = g \\ 60^\circ \times \left(\frac{r-g}{\Delta} + 4\right), & V = b \end{cases} \quad (8)$$

Kemudian  $H$  dibagi dengan 360 dengan tujuan untuk menghasilkan jangkauan nilai antara 0 hingga 1

$$H = \frac{H}{360} \quad (9)$$

Keterangan:

$R$  menyatakan nilai *red* sebelum normalisasi,  $G$  menyatakan nilai *green* sebelum normalisasi,  $B$  menyatakan nilai *blue* sebelum normalisasi,  $r$  menyatakan nilai *red* ternormalisasi,  $g$  menyatakan nilai *green* ternormalisasi,  $b$  menyatakan nilai *blue* ternormalisasi,  $Cmin$  menyatakan nilai terendah dari  $(r, g, b)$ ,  $H$  menyatakan nilai *hue*,  $S$  menyatakan nilai *saturation*,  $V$  menyatakan nilai *value*.

2) Konversi Citra RGB ke grayscale

Citra grayscale merupakan tipe citra yang hanya terdiri dari satu komponen warna, yaitu warna abu-abu. Citra *grayscale* biasanya ditampung dalam representasi 8-bit integer dengan 256 tingkat keabuan, yang memiliki kisaran nilai antara 0 sampai 255. Warna hitam diwakili oleh nilai 0, sedangkan putih diwakili oleh nilai 255 [12][13]. Untuk menciptakan citra *grayscale* yang berasal dari citra RGB, digunakan persamaan (10) [12].

$$g(x, y) = 0.21R_{(x,y)} + 0.72G_{(x,y)} + 0.07B_{(x,y)} \quad (10)$$

Keterangan:

$g(x,y)$  menyatakan tingkat kecerahan citra *grayscale*,  $R_{(x,y)}$  menyatakan tingkat kecerahan warna merah pada citra asal,  $G_{(x,y)}$  menyatakan tingkat kecerahan warna hijau pada citra asal,  $B_{(x,y)}$  menyatakan tingkat kecerahan warna biru pada citra asal.

#### D. Ekstraksi fitur

Ada dua metode ekstraksi fitur yang digunakan dalam penelitian ini, yaitu ekstraksi fitur berdasarkan warna dalam ruang warna HSV dan ekstraksi fitur berdasarkan tekstur dari metode GLCM.

##### 1) Ekstraksi fitur warna HSV

Untuk mengekstrak fitur warna dalam ruang warna HSV, menggunakan persamaan (11) hingga persamaan (13).

$$\mu_H = \frac{1}{P} \sum_{x,y=1}^P f_H(x, y) \quad (11)$$

$$\mu_S = \frac{1}{P} \sum_{x,y=1}^P f_S(x, y) \quad (12)$$

$$\mu_V = \frac{1}{P} \sum_{x,y=1}^P f_V(x, y) \quad (13)$$

Keterangan:

$\mu_H$  menyatakan *mean* dari momen warna  $H$ ,  $\mu_S$  menyatakan *mean* dari momen warna  $S$ ,  $\mu_V$  menyatakan *mean* dari momen warna  $V$ ,  $P$  menyatakan jumlah seluruh piksel pada citra ( $M \times N$ ), dimana  $M$  dan  $N$  merupakan baris dan kolom.

##### 2) Ekstraksi fitur tekstur GLCM

GLCM merupakan sebuah pendekatan yang diterapkan untuk menganalisis fitur tekstur dengan mempertimbangkan sejauh mana kemunculan pasangan dua piksel pada jarak tertentu serta arah sudut yang mencakup  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , serta  $135^\circ$  [14].

Menurut Halarick, metode GLCM memiliki 14 fitur, antara lain *contrast*, *correlation*, *inverse difference moment*, *angular second moment*, *difference variance*, *sum entropy*, *entropy*,

variance, sum variance, max. correlation coef, sum average, difference entropy, dan info measure of correlation 1 dan 2 [15]. Penelitian ini menggunakan jarak piksel sebesar 1, orientasi sudut  $0^\circ$ , dan menggunakan parameter GLCM yang mencakup *contrast*, *correlation*, *energy* (yang juga dikenal sebagai *angular second moment*), dan *homogeneity* (yang juga dikenal sebagai *inverse difference moment*).

Agar dapat melakukan ekstraksi fitur tekstur berdasarkan metode GLCM, terdapat beberapa tahapan yang perlu diikuti sebagaimana diuraikan dalam [16].

(a) Citra *grayscale* dikuantisasi menjadi  $L$  kelompok gradasi, dengan nilai  $L = 8$ . Detail pengelompokannya tercantum dalam **Tabel I**.

**Tabel I.** Kuantisasi 8 gradasi

Level	Nilai
0	0 – 31
1	32 – 63
2	64 – 95
3	96 – 127
4	128 – 159
5	160 – 191
6	192 – 223
7	224 – 256

(b) Pembentukan matriks *co-occurrence* dilakukan dengan langkah-langkah berikut; Pertama, membentuk wilayah kerja dengan 8 kelompok gradasi, sebagaimana terlihat dalam **Gambar 4**.

	0	1	2	3	4	5	6	7
0	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7
1	1,0	1,1	1,2	1,3	1,4	1,5	1,6	1,7
2	2,0	2,1	2,2	2,3	2,4	2,5	2,6	2,7
3	3,0	3,1	3,2	3,3	3,4	3,5	3,6	3,7
4	4,0	4,1	4,2	4,3	4,4	4,5	4,6	4,7
5	5,0	5,1	5,2	5,3	5,4	5,5	5,6	5,7
6	6,0	6,1	6,2	6,3	6,4	6,5	6,6	6,7
7	7,0	7,1	7,2	7,3	7,4	7,5	7,6	7,7

**Gambar 4.** Area kerja matriks 8 kelompok gradasi

Langkah selanjutnya adalah menghitung frekuensi kemunculan setiap elemen di dalam wilayah kerja matriks terhadap citra hasil kuantisasi dengan jarak 1 piksel dan sudut  $0^\circ$ .

(c) Pembentukan matriks simetris dilakukan dengan menggabungkan matriks *co-occurrence* dengan matriks transposenya.

(d) Selanjutnya, dilakukan pembagian nilai dari setiap elemen yang terdapat dalam matriks simetris dengan jumlah total nilai keseluruhan dalam matriks tersebut, dengan tujuan untuk menghasilkan matriks yang ternormalisasi, yang disebut sebagai GLCM.

(e) Perhitungan fitur tekstur dilakukan melalui pemanfaatan parameter berupa *correlation*, *contrast*, *homogeneity*, dan *energy*, yang dihitung dengan menerapkan persamaan (14) hingga persamaan (21) sebagaimana dijelaskan dalam [17].

$$contrast = \sum_{i,j=0}^L (i - j)^2 GLCM(i, j) \quad (14)$$

$$\mu_i = \sum_{i,j=0}^L i \cdot GLCM(i, j) \quad (15)$$

$$\mu_j = \sum_{i,j=0}^L j \cdot GLCM(i, j) \quad (16)$$

$$\sigma_i = \sqrt{\sum_{i,j=0}^L (i - \mu_i)^2 \cdot GLCM(i, j)} \quad (17)$$

$$\sigma_j = \sqrt{\sum_{i,j=0}^L (j - \mu_j)^2 \cdot GLCM(i, j)} \quad (18)$$

$$correlation = \sum_{i,j=0}^L \frac{(i - \mu_i)(j - \mu_j) GLCM(i, j)}{\sigma_i \sigma_j} \quad (19)$$

$$energy = \sum_{i,j=0}^L (GLCM(i, j))^2 \quad (20)$$

$$homogeneity = \sum_{i,j=0}^L \frac{GLCM(i, j)}{1 + (i - j)^2} \quad (21)$$

Keterangan:

$i, j$  menyatakan posisi pada baris  $i$  dan kolom  $j$ ,  $GLCM(i, j)$  menyatakan indeks nilai pada baris  $i$  dan kolom  $j$ ,  $\mu_i$  menyatakan *mean* baris,  $\mu_j$  menyatakan *mean* kolom,  $\sigma_i$  menyatakan standar deviasi baris,  $\sigma_j$  menyatakan standar deviasi kolom.

### E. Klasifikasi Menggunakan *k-Nearest Neighbor*

Metode *k-Nearest Neighbor* ( $k$ -NN) adalah sebuah algoritma yang digunakan untuk mengklasifikasikan suatu objek baru dengan mempertimbangkan data latih yang memiliki jarak terdekat dengan data uji [18].  $k$ -NN adalah algoritma *supervised learning* di mana *class* data uji yang baru akan ditentukan berdasarkan mayoritas *class* pada  $k$  tetangga terdekat dalam data latih [19]. *Class* yang paling dominan dari  $k$  data pelatihan terdekat ini akan menjadi hasil klasifikasi. Langkah-langkah klasifikasi menurut  $k$ -NN [20]:

(a) Penentuan nilai  $k$ .

- (b) Menghitung jarak *Euclidean* [21] antara data pengujian dan setiap data pelatihan dengan menggunakan persamaan (22).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (22)$$

Keterangan:

$d(x,y)$  menyatakan jarak *euclidean*,  $n$  menyatakan banyaknya atribut data,  $x_i$  menyatakan atribut pada data latih ke- $i$ ,  $y_i$  menyatakan atribut pada data uji ke- $i$ .

- (c) Melakukan penyusunan hasil perhitungan jarak *euclidean* dari yang terkecil hingga yang terbesar, dan memilih data pelatihan dengan jarak terdekat dari data uji.
- (d) *Class* yang paling sering terlihat di antara  $k$  data latih tersebut terpilih menjadi kelas yang diatribusikan kepada data uji ini.

### F. Pengujian Menggunakan *K-Fold Cross Validation*

Metode *K-fold* merupakan cara yang dipakai untuk melakukan pengujian dengan cara menggambarkan pembagian acak dari himpunan data menjadi data latih dan data uji, dan pengujian tersebut diulang sebanyak  $K$  kali. Sementara itu, validasi silang (*cross-validation*) merupakan suatu metode statistik yang bertujuan untuk mengevaluasi kinerja suatu algoritma dengan melatih algoritma tersebut pada subset data pembelajaran dan mengujinya pada subset data validasi [22][23]. Langkah-langkah dalam proses *K-Fold Cross Validation* [24]:

- (a) Total *instance* dibagi menjadi  $K$  bagian.

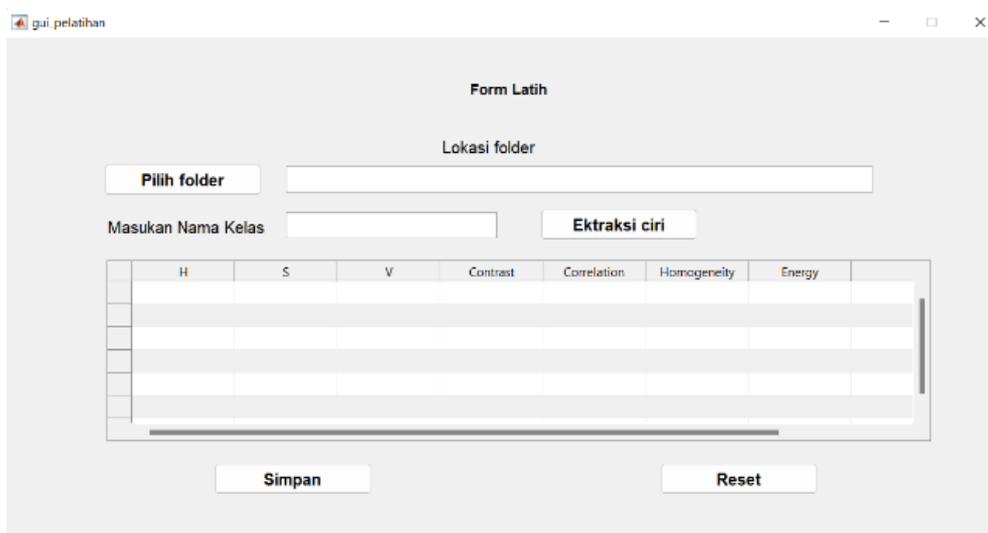
- (b) *Fold* pertama adalah tahap di mana bagian pertama dari data digunakan sebagai data uji, sedangkan sisa data digunakan sebagai data latih. Selanjutnya, akurasi dihitung berdasarkan proporsi data tersebut dengan menggunakan persamaan (23).

$$akurasi = \frac{\sum data\ uji\ klasifikasi\ benar}{\sum data\ uji} \times 100\% \quad (23)$$

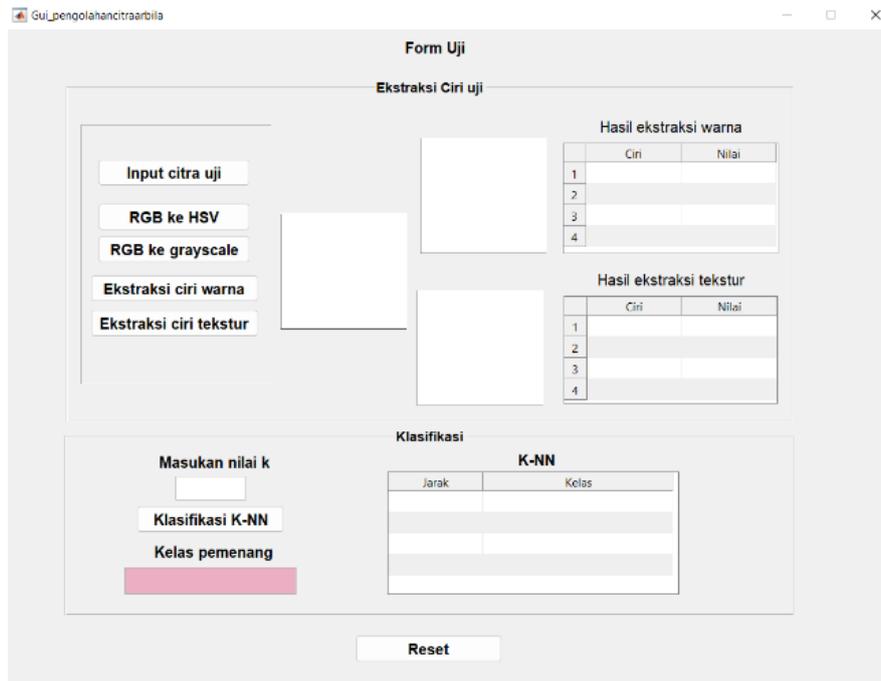
- (c) *Fold* kedua adalah tahap di mana bagian kedua dari data digunakan sebagai data uji, sementara bagian lainnya digunakan sebagai data latih. Setelah itu, akurasi dihitung berdasarkan proporsi data tersebut.
- (d) Proses ini diulang hingga mencapai *fold* ke- $K$ . Kemudian, rata-rata akurasi dari  $K$  *fold* dihitung, yang akan digunakan sebagai nilai akurasi final.

### III. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan sepuluh jenis biji *Arbila* yang ditemukan di Kabupaten Kupang, yaitu *Koto Bona, Koto Bu'u, Koto Ika, Koto Mina, Koto Paratrao Muti Kot Me'e, Kot Paratrao Muti Kot Metan, Koto Sisi, Koto Usif, Beracun 1, dan Beracun 2*, dengan total dataset sebanyak 600 citra. Model yang dikembangkan diimplementasikan menggunakan aplikasi Matlab R2018b, dengan perangkat keras berupa laptop yang memiliki spesifikasi *Intel Core i5 -1135G7, RAM 8 gigabyte, dan SSD 512 gigabyte*. *User interface* dari penelitian ini terdiri dari dua *form*, yaitu *form* latih dan *form* uji, yang dapat dilihat pada **Gambar 5** dan **Gambar 6**.



Gambar 5. User interface dari form latih



Gambar 6. User interface dari form uji

Pada *form* latihan (Gambar 5), data citra biji Arbila dimasukkan untuk mengekstraksi fitur-fitur warna dalam ruang warna HSV, fitur tekstur dengan menggunakan metode GLCM, dan menentukan kelas untuk setiap data citra biji Arbila. Data ini kemudian digunakan sebagai referensi dalam pengujian terhadap data uji. Untuk pengujian memanfaatkan *form* uji (Gambar 6). Pengujian dilakukan dengan menerapkan metode *K-Fold Cross Validation* dengan  $K = 10$  terhadap 600 data citra biji Arbila. Pengujian ini menggunakan metode klasifikasi *k-Nearest Neighbor* dengan variasi nilai  $k$  pada  $NN = 1, 3, 5, 7, \text{ dan } 9$ . Hasil akurasi dari perhitungan ini terdokumentasikan dalam Tabel II.

Tabel II. Hasil pengujian 10-fold

Fold	Akurasi dari tiap $k$ pada NN (%)				
	1	3	5	7	9
1	83,33	81,67	76,67	83,33	80,00
2	91,67	80,00	86,67	78,33	75,00
3	86,67	86,67	83,33	83,33	86,67
4	90,00	85,00	83,33	80,00	78,33
5	91,67	85,00	80,00	83,33	75,00
6	88,33	81,67	80,00	78,33	73,33
7	90,00	86,67	86,67	78,33	80,00
8	86,67	80,00	73,33	73,33	73,33
9	93,33	86,67	86,67	83,33	83,33
10	91,67	91,67	88,33	86,67	88,33
Rata-rata	89,33	84,50	82,50	80,83	79,33

Berdasarkan hasil pengujian pada Tabel II, dapat dijelaskan bahwa *fold* 1, akurasi tertinggi dicapai oleh  $k = 1$  dan  $k = 7$  (83,33%).  $k = 5$  memiliki akurasi terendah (76,67%), menunjukkan bahwa nilai  $k$  yang lebih tinggi dapat menurunkan sensitivitas terhadap data pada *fold* ini. Pada *fold* 2,  $k = 1$  menunjukkan performa terbaik dengan akurasi yang tinggi (91,67%).  $k = 9$  memiliki akurasi terendah (75,00%), menunjukkan bahwa ketika melibatkan lebih banyak tetangga, model kehilangan ketepatan dalam memprediksi. Untuk *fold* 3,  $k = 1, k = 3, \text{ dan } k = 9$  mencapai akurasi tertinggi (86,67%). Ini menunjukkan bahwa untuk *fold* ini, model cukup stabil dengan nilai  $k$  yang berbeda, namun  $k = 5$  dan  $k = 7$  cenderung lebih rendah (83,33%). Pada *fold* 4,  $k = 1$  mencapai akurasi 90%, menunjukkan keakuratan yang tinggi, sementara  $k = 9$  mendapatkan hasil terendah (78,33%). Ini kembali menunjukkan bahwa nilai  $k$  yang lebih tinggi dapat mengurangi akurasi pada *fold* ini. Untuk *fold* 5,  $k = 1$  kembali menunjukkan akurasi yang sangat baik (91,67%), sementara  $k = 9$  menunjukkan performa yang lebih rendah (75,00%).  $k = 3$  juga cukup kompetitif tetapi tidak setinggi  $k = 1$ . Pada *fold* 6,  $k = 1$  masih mempertahankan kinerjanya dengan akurasi 88,33%.  $k = 9$  kembali menunjukkan hasil terendah (73,33%), menyoroti kelemahan penggunaan nilai  $k$  yang lebih tinggi. Untuk *fold* 7,  $k = 1$  mencatat 90%, sementara  $k = 7$  mendapatkan hasil terendah (78,33%). Namun,  $k = 3$  dan  $k = 5$  menunjukkan performa yang

cukup baik (86,67%). Pada *fold* 8,  $k = 1$  tetap menunjukkan kinerja yang baik (86,67%), tetapi untuk  $k = 5$ ,  $k = 7$ , dan  $k = 9$ , semua menunjukkan hasil yang lebih rendah (73,33%). Untuk *fold* 9,  $k = 1$  mencapai akurasi tertinggi (93,33%), menunjukkan performa luar biasa pada *fold* ini. Nilai  $k$  yang lebih besar menunjukkan hasil yang lebih merata tetapi tetap di bawah  $k = 1$ . Dengan demikian, dapat dinyatakan bahwa kelompok data latih pada *fold* ke-9 merupakan yang paling mewakili data uji. Informasi lebih lanjut mengenai sebaran akurasi pada kelompok data *fold* ke-9 dapat ditemukan dalam **Tabel III**. Pada *fold* 10,  $k = 1$  dan  $k = 3$  keduanya menunjukkan performa sangat baik (91,67%).  $k = 5$ ,  $k = 7$ , dan  $k = 9$  tetap kompetitif tetapi tidak mencapai performa  $k = 1$ . Berdasarkan hasil dari setiap *fold*, jelas terlihat bahwa  $k = 1$  secara konsisten memberikan akurasi yang lebih tinggi dibandingkan nilai  $k$  lainnya, menunjukkan bahwa pada *dataset* ini, menggunakan satu tetangga terdekat lebih efektif dalam menangkap pola yang ada. Sebaliknya, nilai  $k$  yang lebih besar cenderung menurunkan akurasi.

Secara umum, dapat dilihat bahwa nilai  $k$  yang lebih rendah ( $k = 1$ ) menghasilkan akurasi tertinggi dibandingkan dengan nilai  $k$  yang lebih tinggi. Akurasi cenderung menurun seiring dengan peningkatan nilai  $k$ . Berdasarkan hasil eksperimen, dapat dinyatakan bahwa nilai  $k$  yang kecil pada algoritma  $k$ -NN memberikan kinerja terbaik dalam klasifikasi citra biji Arbila berdasarkan fitur warna dan tekstur.  $k = 1$  menunjukkan performa tertinggi dengan rata-rata akurasi 89,33%, sementara  $k = 9$  memiliki rata-rata akurasi terendah yaitu 79,33%. Penurunan akurasi seiring dengan bertambahnya nilai  $k$  dapat dijelaskan oleh sifat algoritma  $k$ -NN itu sendiri, di mana nilai  $k$  yang lebih kecil (seperti  $k = 1$ ) lebih mengandalkan tetangga terdekat dalam membuat prediksi, sehingga lebih sensitif terhadap pola lokal dari data. Sebaliknya, nilai  $k$  yang lebih besar ( $k = 9$ ) melibatkan lebih banyak tetangga dalam perhitungan, yang dapat menyebabkan model menjadi terlalu generalisasi dan mengurangi sensitivitas terhadap perbedaan halus dalam fitur gambar biji Arbila. Nilai-nilai  $k$  lainnya seperti  $k = 3$  dan  $k = 5$  menunjukkan performa yang masih cukup kompetitif, masing-masing dengan rata-rata akurasi 84,50% dan 82,50%.

Merujuk pada khusus hasil uji akurasi *fold* ke-9 pada  $k = 1$  (**Tabel III**), merupakan yang paling mewakili data uji, secara rinci dapat dijelaskan bahwa jenis biji Arbila “Beracun 1”, jumlah

prediksi benar 6, akurasi 100%, artinya model berhasil memprediksi semua sampel dari jenis ini dengan tepat. Ini menunjukkan bahwa fitur yang digunakan dapat dengan baik membedakan jenis ini dari yang lainnya.

**Tabel III.** Hasil uji akurasi *fold* ke-9 pada  $k = 1$  untuk NN

Jenis Biji Arbila	Jumlah prediksi benar	Akurasi (%)
Beracun 1	6	100
Beracun 2	5	83,33
Koto Bona	6	100
Koto Bu`u	5	83,33
Koto Ika	5	83,33
Koto Mina	6	100
Koto Paratrao kot Me`e	5	83,33
Koto Paratrao Kot Metan	6	100
Koto Sisi	6	100
Koto Usif	6	100

Jenis biji Arbila “Beracun 2”, jumlah prediksi benar 5, akurasi 83,33%, artinya sebagian besar prediksi untuk jenis ini akurat, meskipun ada beberapa kesalahan. Hal ini menunjukkan bahwa model kesulitan dengan ciri-ciri tertentu yang membedakan “Beracun 2” dari jenis lainnya. Jenis biji Arbila “Koto Bona”, jumlah prediksi benar 6, akurasi 100%, artinya model berhasil mengenali semua sampel dengan tepat, menunjukkan kekuatan dalam mengidentifikasi jenis ini. Jenis biji Arbila “Koto Bu`u”, jumlah prediksi benar 5, akurasi 83,33%, artinya sama seperti “Beracun 2”, sebagian besar prediksi benar, tetapi ada beberapa kesalahan yang diakibatkan oleh kesamaan fitur dengan jenis lain. Jenis biji Arbila “Koto Ika”, jumlah prediksi benar 5, akurasi 83,33%, artinya model tidak sepenuhnya akurat, yang menunjukkan ada kemungkinan *overlap* fitur dengan jenis lain. Jenis biji Arbila “Koto Mina”, jumlah prediksi benar 6, akurasi 100%, artinya semua prediksi benar, menunjukkan bahwa model sangat baik dalam mengenali jenis ini. Jenis biji Arbila “Koto Paratrao kot Me`e”, jumlah prediksi benar 5, akurasi 83,33%, artinya hasil ini mencerminkan performa yang baik, tetapi dengan potensi kesalahan yang perlu dieksplorasi lebih lanjut. Jenis biji Arbila “Koto Paratrao Kot Metan”, jumlah prediksi benar 6, akurasi 100%, artinya model menunjukkan performa yang sangat baik dengan tidak ada kesalahan dalam prediksi untuk jenis ini. Jenis biji Arbila “Koto Sisi”, jumlah prediksi benar 6, akurasi 100%, artinya keberhasilan model dalam mengidentifikasi semua sampel dari jenis ini menunjukkan akurasi yang

tinggi dan pemahaman yang baik dari fitur yang relevan. Jenis biji Arbila “Koto Usif”, jumlah prediksi benar 6, akurasi 100%, artinya sama seperti yang lain dengan akurasi sempurna, ini menunjukkan bahwa model sangat efektif dalam membedakan jenis ini. Kinerja model secara keseluruhan, untuk model  $k$ -NN dengan  $k = 1$  menunjukkan performa yang sangat baik dalam mengklasifikasikan sebagian besar jenis biji Arbila, dengan 70% dari jenis yang diuji mencapai akurasi 100%. Hanya “Beracun 2”, “Koto Bu’u”, “Koto Ika”, dan “Koto Paratrao kot Me’e” yang memiliki akurasi 83,33%. Jenis-jenis biji Arbila yang memiliki akurasi 83,33% menunjukkan area di mana model perlu ditingkatkan, dengan menambahkan lebih banyak fitur atau menggunakan teknik pengolahan data tambahan untuk mengurangi *overlap* dalam fitur-fitur yang digunakan untuk klasifikasi.

Penelitian ini menunjukkan bahwa nilai  $k$  yang lebih kecil ( $k = 1$ ) memberikan akurasi tertinggi dengan rata-rata 89,33%.  $k = 3$  dan  $k = 5$  juga menunjukkan performa yang kompetitif, tetapi semakin besar nilai  $k$ , semakin rendah akurasinya, dengan  $k = 9$  mencatat akurasi terendah (79,33%). Dalam penelitian oleh Sari dan Sari (2022) serta Jerandu dan rekan (2022) [5][6], ditemukan bahwa penggunaan  $k = 3$  menghasilkan akurasi sebesar 90%, sementara pada [9] dan [8], nilai  $k = 1$  memberikan akurasi berturut-turut sebesar 96% dan 90%. Tampak bahwa nilai  $k$  yang kecil cenderung menghasilkan akurasi yang tinggi, mirip dengan temuan dalam penelitian ini. Penelitian tersebut juga mencatat bahwa nilai  $k$  yang lebih besar mengarah pada akurasi yang menurun, yang sejalan dengan hasil penelitian ini. Hasil penelitian kami menguatkan temuan yang ada dalam penelitiannya [9] dan [8], di mana  $k = 1$  menunjukkan performa terbaik. Ini menunjukkan bahwa dalam konteks *dataset* yang dianalisis,  $k$ -NN dengan  $k$  yang lebih kecil lebih efektif dalam menangkap pola lokal dan menghasilkan akurasi yang lebih tinggi.

Secara keseluruhan, hasil penelitian ini memberikan dukungan untuk penggunaan nilai  $k$  yang lebih kecil dalam metode  $k$ -NN untuk meningkatkan akurasi, terutama dalam *dataset* yang memiliki pola yang lebih lokal.

#### IV. KESIMPULAN

Penelitian ini telah berhasil mengembangkan model klasifikasi biji Arbila (*Phaseolus lunatus L.*) menggunakan metode  $k$ -Nearest Neighbor ( $k$ -NN) yang menggabungkan ekstraksi fitur warna dalam

model HSV dan tekstur menggunakan *Gray Level Co-Occurrence Matrix* (GLCM). Dari sepuluh jenis biji Arbila yang diteliti, model klasifikasi menunjukkan kinerja yang sangat baik, terutama pada nilai  $k = 1$ , yang mencapai rata-rata akurasi 89,33%. Model ini berhasil mengidentifikasi 70% dari jenis biji yang diuji dengan akurasi 100%, menunjukkan efektivitas fitur yang digunakan dalam membedakan jenis biji Arbila. Penelitian ini tidak hanya memberikan kontribusi terhadap peningkatan akurasi klasifikasi biji Arbila tetapi juga membuka peluang untuk pengembangan lebih lanjut dalam klasifikasi citra dengan memanfaatkan kombinasi fitur warna dan tekstur. Dengan demikian, penelitian ini dapat memberikan manfaat signifikan bagi pengembangan pertanian lokal dan kesehatan masyarakat melalui pemilihan biji Arbila yang tepat.

Penelitian lanjutan dapat mengeksplorasi kombinasi metode klasifikasi lain serta pendekatan yang lebih adaptif dalam mengidentifikasi biji Arbila, terutama untuk jenis-jenis yang memiliki ciri yang sangat mirip.

#### DAFTAR PUSTAKA

- [1] B. B. Koten, R. D. Soetrisno, N. Ngadiyono, and B. Soewignyo, “Penampilan Produksi Hijauan Hasil Tumpangsari Arbila (*Phaseolus lunatus*) Berinokulum *Rhizobium* dan Sorgum (*Sorghum bicolor*) pada Jarak Tanam Arbila dan Jumlah Baris Sorgum,” *Sains Peternak.*, vol. 11, no. 1, pp. 26–33, 2013, [Online]. Available: <https://jurnal.uns.ac.id/Sains-Peternakan/article/view/4846>
- [2] B. B. Koten, E. Natal, R. Wea, M. D. Randu, A. Aoetpah, and C. Sabuna, “Identification Of Weight And Size Diversity Of Arbila (*Phaseolus lunatus L.*) Seed As Feed In Amabi Oefeto District, Kupang Regency,” in *Proceedings of the 6th International Seminar of Animal Nutrition and Feed Science (ISANFS 2021)*, Atlantis Press, 2022, pp. 118–122. doi: 10.2991/absr.k.220401.025.
- [3] H. Sujaini, “Sistem Analisis Citra Alat Musik Tradisional dengan Metode  $k$ -Nearest Neighbor, Random Forest, dan Support Vector Machine,” *J. Sist. Inf. BISNIS*, vol. 9, no. 2, p. 185, Nov. 2019, doi: 10.21456/vol9iss2pp185-191.
- [4] N. Wijaya and A. Ridwan, “Klasifikasi Jenis Buah Apel Dengan Metode  $k$ -Nearest Neighbors Dengan Ekstraksi Fitur Hsv Dan Lbp,” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 8, no. 1, pp. 74–78, Apr. 2019, doi: 10.32736/sisfokom.v8i1.610.
- [5] C. Y. Jerandu, P. Batarius, and A. A. J. Sinlae, “Identifikasi Kualitas Kesegaran Ikan Menggunakan Algoritma  $k$ -Nearest Neighbor Berdasarkan Ekstraksi Ciri Warna Hue, Saturation, dan Value (HSV),” *Build. Informatics, Technol. Sci.*, vol. 4, no. 3, pp. 1536–1547, Dec. 2022, doi: 10.47065/bits.v4i3.2613.
- [6] W. S. Sari and C. A. Sari, “KLASIFIKASI BUNGA MAWAR MENGGUNAKAN KNN DAN EKSTRAKSI FITUR GLCM DAN HSV,” *SKANIKA*, vol. 5, no. 2, pp. 145–156, Jul. 2022, doi: 10.36080/skanika.v5i2.2951.
- [7] N. E. R. Pah, S. A. S. Mola, and A. Y. Mauko, “Ekstraksi Ciri Warna Hsv dan Ciri Bentuk Moment Invariant Untuk Klasifikasi Buah Apel Merah,” *J. Komput. dan Inform.*, vol. 9, no. 2, pp. 142–153, Sep. 2021, doi: 10.35508/jicon.v9i2.5043.
- [8] S. A. Rosiva Srg, M. Zarlis, and W. Wanayumini, “Identifikasi Citra Daun dengan GLCM (Gray Level Co-Occurrence) dan  $k$ -NN ( $k$ -Nearest Neighbor),” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 21, no. 2, pp. 477–488,

- Mar. 2022, doi: 10.30812/matrik.v2i12.1572.
- [9] D. Suryani, W. I. Sabilla, and H. L. Wicaksono, "Identifikasi Kualitas Cabai Berdasarkan Warna dan Tekstur Dengan Menggunakan Metode K- Nearest Neighbor," *Semin. Inform. Apl. POLINEMA*, pp. 438–443, 2020, [Online]. Available: <http://jurnalti.polinema.ac.id/index.php/SIAP/article/view/833>
- [10] I. G. A. A. D. Indradewi and M. S. Andriantini, "Jaringan Syaraf Tiruan LVQ Berbasis Parameter HSV dalam Penentuan Uang Rupiah Palsu," *J. Ilm. Teknol. Inf. Asia*, vol. 13, no. 1, pp. 47–52, 2019, [Online]. Available: <https://jurnal.stmikasia.ac.id/index.php/jitika/article/view/291>
- [11] D. I. Mulyana, A. B. Zuhari, and M. B. Yel, "Klasifikasi Citra Burung Jalak Bali dengan Menggunakan Algoritma K-Nearest Neighbor (KNN)," *J. Tek. Elektro dan Komputasi*, vol. 5, no. 1, pp. 57–67, Mar. 2023, doi: 10.32528/elkom.v5i1.9337.
- [12] F. A. Rafi, A. Faggidae, and Y. T. Polly, "Asphalt Road Damage Detection System Using Canny Edge Detection," *J. Komput. dan Inform.*, vol. 11, no. 1, pp. 85–90, Mar. 2023, doi: 10.35508/jicon.v11i1.10100.
- [13] L. Satrio Tegar and J. Utama, "Rancang Bangun Sistem Informasi Lahan Parkir Kendaraan Roda Empat di Unikom Berbasis Image Processing," *Telekontran J. Ilm. Telekomun. Kendali dan Elektron. Terap.*, vol. 4, no. 1, pp. 27–33, 2016.
- [14] R. A. Surya, A. Fadlil, and A. Yudhana, "Ekstraksi Ciri Metode Gray Level Co-Occurrence Matrix ( GLCM ) dan Filter Gabor untuk Klasifikasi Citra Batik Pekalongan," *J. Inform. Pengemb. IT*, vol. 02, no. 02, pp. 23–26, 2017, doi: 10.30591/jpit.v2i2.520.
- [15] W. I. Praseptiyana, A. W. Widodo, and M. A. Rahman, "Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) untuk Deteksi Melasma pada Citra Wajah," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 11, pp. 10402–10409, 2019, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/6685>
- [16] B. Sofiandi, J. Raharjo, and K. Usman, "Identifikasi Pola Citra Iris Mata Untuk Mendeteksi Kelebihan Kadar Kolesterol Menggunakan Metode Gray Level Co-Occurrence Matrix (GLCM) dan Decision Tree," *e-Proceeding Eng.*, vol. 6, no. 3, pp. 10242–10249, 2019, [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/11348>
- [17] K. N. N. Hlaing and A. K. Gopalakrishnan, "Myanmar paper currency recognition using GLCM and k-NN," in 2016 Second Asian Conference on Defence Technology (ACDT), Chiang Mai, Thailand: IEEE, Jan. 2016, pp. 67–72. doi: 10.1109/ACDT.2016.7437645.
- [18] S. Charan, S. M.S, and S. R., "Prediction of Insufficient Accuracy for Human Activity Recognition with Limited Range of Age using K-Nearest Neighbor," in 2023 Second International Conference on Electronics and Renewable Systems (ICEARS), IEEE, Mar. 2023, pp. 926–930. doi: 10.1109/ICEARS56392.2023.10085062.
- [19] S. P. Tanzil and M. R. Pribadi, "Analisis Sentimen Pengguna Instagram terhadap Timnas Indonesia U-23 pada Piala AFC menggunakan Algoritma K-Nearest Neighbor (K-NN) dengan Synthetic Minority Over-sampling Technique (SMOTE) Sentiment Analysis of Instagram User's towards the Indonesia U-23," *TELEKONTRAN J. Ilm. Telekomun. Kendali dan Elektron. Terap.*, vol. 12, no. 1, pp. 68–80, 2024.
- [20] A. J. T, D. Yanosma, and K. Anggriani, "Implementasi Metode K-Nearest Neighbor (Knn) Dan Simple Additive Weighting (Saw) Dalam Pengambilan Keputusan Seleksi Penerimaan Anggota Paskibraka," *Pseudocode*, vol. 3, no. 2, pp. 98–112, Jan. 2017, doi: 10.33369/pseudocode.3.2.98-112.
- [21] M. Bansal, A. Goyal, and A. Choudhary, "A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning," *Decis. Anal. J.*, vol. 3, no. November 2021, pp. 100071, Jun. 2022, doi: 10.1016/j.dajour.2022.100071.
- [22] I. Iswanto, T. Tulus, and P. Poltak, "Comparison Of Feature Selection To Performance Improvement Of K-Nearest Neighbor Algorithm In Data Classification," *J. Tek. Inform.*, vol. 3, no. 6, pp. 1709–1716, Dec. 2022, doi: 10.20884/1.jutif.2022.3.6.471.
- [23] N. T. Pitaloka and K. Kusnawi, "Pcos Disease Classification Using Feature Selection Rfcv And Eda With Knn Algorithm Method," *J. Tek. Inform.*, vol. 4, no. 4, pp. 693–701, Aug. 2023, doi: 10.52436/1.jutif.2023.4.4.831.
- [24] L. Mardiana, D. Kusnandar, and N. Satyahadewi, "Analisis Diskriminan Dengan K Fold Cross Validation Untuk Klasifikasi Kualitas Air Di Kota Pontianak," *Bul. Ilm. Mat. Stat. dan Ter.*, vol. 11, no. 1, pp. 97–102, 2022, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jbmstr/article/view/51608>