

Implementasi Algoritma K-Means untuk Klasifikasi Citra Biota Laut: Gurita, Lobster, dan Kerang Laut

Muhammad Dicky Imansyah¹, Agung Ramadhanu²

^{1,2}Magister Teknik Informatika, Fakultas Ilmu Komputer, Universitas Putra Indonesia “YPTK” Padang

¹dickyimansyah007@gmail.com, ²agung_ramadhanu@upiypk.ac.id

Submitted: 28-09-2025, Reviewed: 30-09-2025, Accepted 05-10-2025

<https://doi.org/10.47233/jteksis.v7i4.2271>

Abstract

*Octopus, lobster, and shellfish are high-value fishery commodities that are still classified manually, leading to potential subjectivity, inefficiency, and human error. This study proposes a novel framework that integrates L^*a^*b color space conversion, K-Means clustering for segmentation, and hybrid feature extraction combining shape (metric and eccentricity) and texture features (GLCM: contrast, correlation, energy, homogeneity) to automate the classification of marine biota a field that remains underexplored in computer vision. The main novelty of this work lies in the tailored combination of color, shape, and texture analysis specifically designed for the morphological characteristics of octopus, lobster, and shellfish. Testing on a limited dataset of 30 images (10 per category) achieved an average accuracy of 95%, demonstrating the effectiveness of the proposed method in distinguishing the three species. However, the study's limitations include the small dataset size and controlled imaging conditions, which may affect model generalizability to real-world environments. Despite these constraints, this research provides a significant contribution as a computer vision-based solution for the fisheries sector, with potential applications in automated sorting systems.*

Keywords: K-Means Clustering, Image Processing, Marine Biota, Image Classification, Segmentation

Abstrak

Gurita, lobster, dan kerang merupakan komoditas perikanan bernilai tinggi yang masih diklasifikasikan secara manual, yang berpotensi menyebabkan subjektivitas, ketidak efisienan, dan kesalahan manusia. Penelitian ini mengusulkan kerangka kerja inovatif yang menggabungkan konversi ruang warna L^*a^*b , pengelompokan K-Means untuk segmentasi, dan ekstraksi fitur hibrida yang menggabungkan fitur bentuk (metrik dan eksentrisitas) dan fitur tekstur (GLCM: kontras, korelasi, energi, homogenitas) untuk mengotomatisasi klasifikasi biota laut, bidang yang masih kurang dieksplorasi dalam penglihatan komputer. Keunikan utama penelitian ini terletak pada kombinasi yang disesuaikan antara analisis warna, bentuk, dan tekstur yang dirancang khusus untuk karakteristik morfologis gurita, lobster, dan kerang. Pengujian pada dataset terbatas sebanyak 30 gambar (10 per kategori) mencapai akurasi rata-rata 95%, menunjukkan keefektifan metode yang diusulkan dalam membedakan ketiga spesies tersebut. Namun, keterbatasan studi ini meliputi ukuran dataset yang kecil dan kondisi pemotretan yang terkontrol, yang dapat memengaruhi generalisasi model ke lingkungan dunia nyata. Meskipun demikian, penelitian ini memberikan kontribusi signifikan sebagai solusi berbasis penglihatan komputer untuk sektor perikanan, dengan potensi aplikasi dalam sistem penyortiran otomatis.

Kata kunci: K-Means Clustering, Pengolahan Citra, Biota Laut, Klasifikasi Citra, Segmentasi

This work is licensed under Creative Commons Attribution License 4.0 CC-BY International license



PENDAHULUAN

Perkembangan teknologi pengolahan citra digital dan machine learning seperti clustering turut mendorong efisiensi di berbagai sektor, termasuk bidang kelautan dan perikanan [1]. Gurita, lobster, dan kerang laut merupakan komoditas perikanan yang memiliki nilai ekonomi tinggi. Namun, klasifikasi jenis-jenis hewan ini masih sering mengandalkan metode manual yang bersifat subjektif, memakan waktu, serta rentan terhadap kesalahan manusia, terutama dalam volume besar seperti di pelabuhan pelelangan ikan atau unit pengolahan [2].

Pengolahan citra digital memungkinkan ekstraksi informasi dari gambar berupa bentuk, tekstur, warna dan ukuran yang dapat digunakan untuk proses klasifikasi [3]. Salah satu metode

yang umum digunakan adalah *K-Means Clustering*, metode ini digunakan untuk mengklasifikasikan pixel citra berdasarkan fitur visual dan dikombinasikan dengan teknik pengolahan citra lainnya seperti segmentasi dan ekstraksi fitur untuk meningkatkan akurasi [4].

Penelitian sebelumnya telah menunjukkan keberhasilan penggunaan *K-means Clustering* dalam klasifikasi objek berdasarkan citra digital, seperti klasifikasi batu kerikil dan batu kali [5], identifikasi kematangan timun [6], serta klasifikasi apel Fuji dan apel hijau [7]. Namun, penerapan metode tersebut untuk klasifikasi biota laut (gurita, lobster, kerang laut) masih sangat terbatas. Oleh karena itu, penelitian ini hadir untuk mengisi celah tersebut dengan mengembangkan model klasifikasi citra digital

biota laut menggunakan metode *K-Means Clustering* yang didahului oleh tahapan pra-pengolahan citra (*image processing*).

Hasil penelitian ini diharapkan dapat memberikan kontribusi praktis yang signifikan bagi sektor perikanan. Model klasifikasi otomatis yang dikembangkan berpotensi untuk diimplementasikan dalam proses sorting hasil tangkapan di pelabuhan Tempat Pelelangan Ikan (TPI) atau Unit Pengolahan Ikan (UPI). Hal ini akan meningkatkan efisiensi operasional, mengurangi ketergantungan pada tenaga kerja ahli, meminimalkan kesalahan klasifikasi, dan pada akhirnya berkontribusi terhadap peningkatan produktivitas serta nilai ekonomi dalam rantai pasok perikanan.

METODE PENELITIAN

Penelitian ini mengikuti tahapan sistematis seperti ditunjukkan pada Gambar 1. Tahapan dimulai dari pengumpulan data, pra-pemrosesan, segmentasi, ekstraksi fitur, hingga identifikasi.




Gambar 1. Tahapan Klasifikasi

2.1. Pengumpulan Data

Dataset citra diperoleh dari hasil pemotretan langsung objek gurita, lobster, dan kerang laut menggunakan kamera DSLR Canon EOS 700D dengan resolusi HD. Pemotretan dilakukan dalam kondisi pencahayaan terkendali untuk meminimalkan variasi intensitas cahaya dan bayangan. Latar belakang yang digunakan seragam (warna putih) untuk mempermudah proses segmentasi. Jumlah total citra yang digunakan adalah 30 citra, dengan distribusi 10 citra untuk setiap kategori biota laut (gurita, lobster, dan kerang laut). Seluruh pemrosesan citra dan implementasi algoritma dilakukan menggunakan perangkat lunak MATLAB R2024a pada komputer dengan prosesor Intel Core i7 dan RAM 16 GB.

2.2 Transformasi Citra L^*a^*b

Citra RGB dikonversi ke ruang warna L^*a^*b untuk memisahkan informasi luminansi dan warna [8]. Konversi ini memudahkan proses segmentasi dengan memisahkan objek dari latar belakang.



Gambar 2. Transformasi L^*a^*b Gurita



Gambar 3. Transformasi L^*a^*b Lobster



Gambar 4. Transformasi L^*a^*b Kerang Laut

2.3 Segmentasi K-Means Clustering

K-Means Clustering merupakan sebuah algoritma metode pengklasifikasian objek ke satu kelompok atau lebih berdasarkan kemiripan objek, dimana objek yang sama dimasukkan kedalam satu kelompok dan kelompok lain berisi objek yang berbeda dengan yang ada pada kelompok sebelumnya. Proses pengelompokan dengan algoritma *K-Means* dengan rumus K . $K=2$ menandakan bahwa terdapat dua pengelompokan dan jika $K=3$ maka pengelompokan ada tiga [2], [6], [7].

Algoritma *K-Means* diterapkan pada saluran a^* dan b^* untuk mengelompokkan piksel menjadi tiga cluster sesuai jenis biota laut. Proses iterasi dilakukan terus-menerus sampai hasilnya konvergen. Dalam penelitian ini, penulis menggunakan metode *K-Means Clustering* dengan rumus seperti berikut:

Algoritma *K-Means* untuk Segmentasi Citra:

- Inisialisasi *Centroid*: Pilih 3 *centroid* awal secara acak ($K=3$ sesuai jumlah kategori biota laut)
- *Assignment Step*: Setiap piksel dialokasikan ke cluster terdekat berdasarkan jarak *Euclidean*
- *Update Centroid*: Hitung *centroid* baru sebagai rata-rata piksel dalam cluster
- Iterasi: Ulangi langkah 2-3 hingga konvergen

Fungsi Objektif:

$$J = \sum_{i=1}^n \sum_{j=1}^k w_{ij}^2 \|x_i - \mu_j\| \quad (1)$$

Keterangan:

J = Fungsi objektif yang diminimalkan

n = Jumlah total piksel dalam citra

k = Jumlah *cluster* yang diinginkan

w_{ij} = Indikator keanggotaan (1 jika piksel i termasuk *cluster* j, 0 jika tidak)

x_i = Vektor fitur piksel ke-i

μ_j = *Centroid cluster* ke-j

Jarak *Euclidean*:

$$d(x_i, \mu_j) = \sqrt{[(x_{i1} - \mu_{j1})^2 + (x_{i2} - \mu_{j2})^2 + \dots + (x_{id} - \mu_{jd})^2]} \quad (2)$$

Keterangan:

d = Jarak *Euclidean* antara piksel dan *centroid*

x_{im} = Nilai fitur ke-m dari piksel i

μ_{jm} = Nilai fitur ke-m dari *centroid* j

Update *Centroid*:

$$\mu_j^{\{(t+1)\}} = \left(\frac{1}{|C_j|} \right) \times \sum_{x_i \in C_j} x_i \quad (3)$$

Keterangan:

$\mu_j^{\{(t+1)\}}$ = *Centroid* baru *cluster* j pada iterasi t+1

$|C_j|$ = Jumlah piksel dalam *cluster* j

$\sum_{x_i \in C_j} x_i$ = Jumlah semua vektor piksel dalam *cluster* j


Kriteria Konvergensi:

$$\left\| \mu_j^{\{(t+1)\}} - \mu_j^{\{(t)\}} \right\| < \varepsilon \quad (4)$$


Keterangan:

ε = Threshold konvergensi (biasanya 0.001)


t = Iterasi ke-t



Gambar 5. Segmentasi Citra dengan *K-Means Clustering* Gurita



Gambar 6. Segmentasi Citra dengan *K-Means Clustering* Lobster



Gambar 7. Segmentasi Citra dengan *K-Means Clustering* Kerang Laut

2.4 Ekstraksi Citra Bentuk dan Tekstur

Setelah proses segmentasi citra menggunakan metode *K-Means Clustering*, tahap berikutnya adalah ekstraksi fitur. Ekstraksi fitur bertujuan untuk mengidentifikasi dan memperoleh karakteristik unik dari setiap objek yang akan dibedakan. Dalam penelitian ini, ekstraksi fitur dilakukan pada dua aspek, yaitu bentuk dan tekstur [9].

a. Bentuk

Fitur bentuk (*shape features*) digunakan untuk menggambarkan karakteristik geometris dari objek. Dua parameter yang digunakan dalam penelitian ini adalah *metric* dan *eccentricity* [10].

1. *Metric* adalah ukuran yang digunakan untuk mengetahui seberapa bulat suatu objek. Nilai *metric* dihitung dengan membandingkan luas area objek tersebut dengan kelilingnya. Rumus yang digunakan adalah:

$$M = \frac{(4\pi \times A)}{C^2} \quad (5)$$


Di mana A mewakili luas area objek dan C merupakan keliling (perimeter) objek. Nilai dari

metrik ini berada dalam rentang 0 hingga 1, di mana nilai mendekati 1 menunjukkan bentuk objek yang sempurna dan bulat, sedangkan nilai yang lebih rendah menunjukkan bentuk yang lebih tidak beraturan [9].


2. *Eccentricity* mengukur sejauh mana bentuk objek mendekati bentuk elips. Parameter ini dihitung dengan membandingkan panjang sumbu minor dan sumbu mayor dari elips tersebut. Rumus untuk menghitung *eccentricity* adalah:

$$e = \sqrt{1 - \left(\frac{b^2}{a^2}\right)} \quad (6)$$


Di mana a adalah panjang sumbu utama dan b adalah panjang sumbu pendek. Nilai ketidakteraturan berada dalam rentang antara 0 (bentuk lingkaran) hingga 1 (bentuk garis lurus) [10].



Gambar 8. Ekstraksi Bentuk Gurita



Gambar 9. Ekstraksi Bentuk Lobster



Gambar 10. Ekstraksi Bentuk Kerang Laut

b. Tekstur

Fitur tekstur menggambarkan pola distribusi intensitas piksel dalam sebuah gambar. Dalam penelitian ini, metode yang digunakan untuk

mengeksrak fitur tekstur adalah *Gray Level Co-occurrence Matrix* (GLCM). GLCM merupakan matriks yang menunjukkan seberapa sering dua piksel dengan intensitas tertentu muncul bersama pada jarak dan arah tertentu [11]. Empat fitur tekstur yang dihitung dari GLCM adalah:

1. *Contrast* mengukur tingkat perbedaan kekuatan cahaya antara suatu piksel dengan piksel-piksel di sekitarnya. Kontras dihitung menggunakan rumus:

$$Contrast = \sum_i \sum_j (i - j)^2 \times P(i, j) \quad (7)$$

Di mana $P(i, j)$ adalah elemen GLCM pada baris i dan kolom j .

2. *Correlation* mengevaluasi hubungan linear antara intensitas piksel yang berdekatan. Rumus korelasi adalah:

$$Correlation = \sum_i \sum_j \frac{[(i - \mu_i)(j - \mu_j) \times P(i, j)]}{(\sigma_i \times \sigma_j)} \quad (8)$$


Di mana μ_i dan μ_j adalah rata-rata, sedangkan σ_i dan σ_j adalah simpangan baku dari baris dan kolom GLCM.

3. *Energy* merepresentasikan ukuran keseragaman tekstur. *Energy* dihitung dengan:


$$Energy = \sum_i \sum_j P(i, j)^2 \quad (9)$$

4. *Homogeneity* mengukur kedekatan distribusi elemen GLCM dengan diagonalnya. Rumus *homogeneity* adalah:


$$Homogeneity = \sum_i \sum_j \frac{P(i, j)}{(1 + |i - j|)} \quad (10)$$



Gambar 11. Ekstraksi Tekstur Gurita



Gambar 12. Ekstraksi Tekstur Lobster




Gambar 13. Ekstraksi Teksstur Kerang Laut


HASIL DAN PEMBAHASAN

1. Analisis Fitur


Proses konversi ruang warna RGB $\rightarrow$ L^*a^*b diikuti K -Means (pada saluran a^* dan b^*) berhasil memisahkan objek dari latar belakang sehingga segmentasi objek (gurita, lobster, kerang laut) dapat diperoleh dengan jelas (lihat Gambar 14-16).



Gambar 14. Hasil Pemrosesan dan Ekstraksi Karakteristik Gurita



Gambar 15. Hasil Pemrosesan dan Ekstraksi Karakteristik Lobster



Gambar 16. Hasil Pemrosesan dan Ekstraksi Karakteristik Kerang Laut

2. Kinerja Klasifikasi dan Analisis Mendalam Confusion Matrix

Sistem klasifikasi diuji menggunakan seluruh 30 citra (10 citra per kelas) dengan pendekatan *nearest neighbor* berdasarkan jarak *Euclidean* vektor fitur. Hasil pengujian menunjukkan kinerja yang sangat baik dengan akurasi rata-rata 95%.

Untuk menganalisis performa klasifikasi secara lebih mendalam dan mendeteksi pola kesalahan yang terjadi, *Confusion Matrix* disajikan pada Tabel 1.

Table 1. Hasil Klasifikasi *Confusion Matrix*

Aktual \ Prediksi	Gurita	Lobster	Kerang	Jumlah
Gurita	9	1	0	10
Lobster	0	10	0	10
Kerang	0	0	10	10

Analisis Mendalam *Confusion Matrix*:

Confusion Matrix pada Tabel 1 mengungkapkan performa klasifikasi untuk setiap kelas secara detail:

a. Akurasi per Kelas (*Recall*):

- Kelas Lobster dan Kerang Laut mencapai recall 100%. Artinya, seluruh citra lobster (10) dan kerang laut (10) berhasil diidentifikasi dengan benar oleh sistem. Hal ini menunjukkan bahwa kombinasi fitur bentuk (*eccentricity* tinggi untuk lobster dan *metric* tinggi untuk kerang) sangat efektif dan konsisten dalam membedakan kedua kelas ini.
- Kelas Gurita mencapai *recall* 90% (9 dari 10 citra berhasil dikenali). Satu citra gurita salah diklasifikasikan sebagai lobster.

b. Analisis Kesalahan Klasifikasi:

- Terjadi satu *false positive* untuk kelas lobster, yang sebenarnya adalah citra gurita. Dengan kata lain, model “mengira” satu gurita adalah lobster.
- Penyebab kesalahan ini diduga kuat berkaitan dengan variasi pose objek. Gurita yang memiliki tentakel fleksibel dapat terlihat memanjang pada sudut pengambilan gambar tertentu, sehingga nilai *eccentricity*-nya (yang biasanya mencirikan lobster) menjadi tinggi dan mendekati karakteristik lobster. Analisis fitur pada citra yang salah ini kemungkinan menunjukkan nilai *eccentricity* yang tidak biasa untuk gurita, sehingga sistem tergelincir ke kelas lobster yang secara fitur bentuk lebih mirip.

c. Presisi per Kelas:

- Gurita: Presisi = $9 / (9 + 0) = 100\%$. Semua prediksi “gurita” oleh sistem adalah benar. Tidak ada citra lain yang salah diklasifikasikan sebagai gurita.

- Lobster: Presisi = $10 / (10 + 1) = 90.9\%$. Sebagian besar prediksi “lobster” adalah benar, dengan satu kesalahan dari citra gurita.
- Kerang Laut: Presisi = $10 / (10 + 0) = 100\%$. Semua prediksi “kerang laut” oleh sistem adalah benar.

d. Kesimpulan dari *Confusion Matrix*:

- Sistem bekerja dengan sangat baik untuk kelas lobster dan kerang laut, menunjukkan bahwa fitur yang dipilih sangat representatif untuk kedua kelas ini.
- Kelas gurita memiliki kinerja yang sedikit lebih rendah karena sifat morfologinya yang lebih variabel. Ini menyoroti pentingnya menambah variasi data latih untuk gurita dengan berbagai pose dan orientasi untuk meningkatkan ketangguhan model.

Hasil ekstraksi fitur dari citra (Tabel 1-3) memberikan dasar kuantitatif bagi keberhasilan klasifikasi. Analisis fitur ini konsisten dengan temuan dari *Confusion Matrix*.

Tabel 2. Nilai Ekstraksi Karakteristik Gurita

Ciri	Nilai
Metric	0.03107
Eccentricity	0.45153
Contrast	0.79743
Correlation	0.90337
Energy	0.34798
Homogeneity	0.85486

Tabel 3. Nilai Ekstraksi Karakteristik Lobster

Ciri	Nilai
Metric	0.22923
Eccentricity	0.99485
Contrast	0.06169
Correlation	0.83633
Energy	0.93326
Homogeneity	0.99005

Tabel 4. Nilai Ekstraksi Karakteristik Kerang Laut

Ciri	Nilai
Metric	0.85196
Eccentricity	0.33294

Contrast	0.39961
Correlation	0.97013
Energy	0.36605
Homogeneity	0.92190

Interpretasi temuan:

- Bentuk: Nilai *eccentricity* yang sangat tinggi pada lobster (≈ 0.99) secara konsisten mencerminkan bentuk tubuhnya yang memanjang, sementara kerang laut memiliki *metric* tinggi (≈ 0.85) yang mengindikasikan bentuknya yang bulat dan kompak. Kombinasi kedua fitur bentuk ini sangat efektif membedakan lobster dan kerang, yang tercermin dari *recall* 100% untuk kedua kelas.
- Tekstur: Gurita memiliki nilai *contrast* yang tinggi (≈ 0.80), mencerminkan tekstur permukaan tubuhnya yang lebih beragam dan kompleks dibandingkan lobster dan kerang. Sementara itu, lobster dan kerang menunjukkan tekstur yang lebih seragam (nilai *energy* dan *homogeneity* yang tinggi). Profil tekstur yang unik inilah yang umumnya berhasil membedakan gurita, meskipun dalam satu kasus fitur bentuknya yang atipikal menyebabkan kesalahan klasifikasi.

3. Perbandingan dengan Metode Lain

Sebagai pembandingan, penelitian ini juga menguji pendekatan yang hanya mengandalkan fitur warna (histogram RGB) dan segmentasi berbasis *Thresholding Otsu*. Metode pembandingan tersebut hanya mencapai akurasi rata-rata 76,7%, jauh di bawah metode yang diusulkan dalam penelitian ini (95%).

a. Analisis Perbandingan:

- Metode Pembandingan (Histogram RGB + Otsu): Metode ini gagal menangkap karakteristik morfologi yang mendalam. Segmentasi Otsu yang hanya berdasarkan intensitas seringkali tidak akurat jika latar belakang dan objek memiliki kontras rendah. Sementara itu, histogram RGB sangat sensitif terhadap perubahan pencahayaan dan tidak dapat membedakan objek dengan palet warna yang mirip tetapi bentuk dan teksturnya sangat berbeda.
- Metode yang Diusulkan ($L^*a^*b + K\text{-Means}$ + Fitur Bentuk & Tekstur): Keunggulan metode ini terletak pada:
 1. Segmentasi yang Lebih Robust: Konversi L^*a^*b dan $K\text{-Means}$ pada saluran warna a^* dan b^* berhasil memisahkan objek dengan lebih baik.

2. Fitur yang Lebih Informatif: Kombinasi fitur bentuk (*metric, eccentricity*) dan tekstur (GLCM) memberikan representasi yang jauh lebih kaya dan diskriminatif tentang setiap kelas biota, yang tidak dapat dicapai hanya dengan informasi warna.

Perbandingan ini memperkuat argumen bahwa pendekatan *hybrid* yang mengintegrasikan informasi warna (untuk segmentasi), bentuk, dan tekstur merupakan kunci keberhasilan klasifikasi dalam penelitian ini, menghasilkan akurasi yang secara signifikan lebih tinggi dibandingkan metode tradisional yang hanya mengandalkan warna.

SIMPULAN

Berdasarkan hasil eksperimen dan analisis, dapat disimpulkan bahwa implementasi konversi RGB→L*a*b* diikuti segmentasi *K-Means* serta ekstraksi fitur bentuk (*metric, eccentricity*) dan tekstur GLCM (*contrast, correlation, energy, homogeneity*) efektif untuk klasifikasi citra tiga jenis biota laut (gurita, lobster, kerang laut).

Kontribusi utama penelitian ini adalah menyediakan sebuah *framework* klasifikasi otomatis yang akurat dan konsisten untuk komoditas perikanan bernilai tinggi, yang dapat menjadi dasar pengembangan sistem sorting otomatis di industri perikanan. Sistem mencapai akurasi rata-rata 95% pada pengujian 30 citra (10 per kelas). Keberhasilan klasifikasi ditopang oleh perbedaan jelas pada fitur bentuk (mis. *eccentricity* tinggi untuk lobster, *metric* tinggi untuk kerang laut) dan karakter tekstur (mis. *contrast* tinggi pada gurita).

Namun, penelitian ini memiliki beberapa keterbatasan. Keterbatasan utama adalah ukuran dataset yang kecil (30 citra) dan kurangnya variasi dalam kondisi pencahayaan, sudut pengambilan gambar, serta latar belakang. Hal ini membatasi kemampuan generalisasi model untuk kondisi asli yang lebih kompleks.

Untuk penelitian selanjutnya direkomendasikan: memperbesar ukuran dataset dan menambah variasi kondisi (sudut, jarak, pencahayaan, latar belakang), menerapkan teknik augmentasi citra, mengoptimalkan tahap segmentasi (mis. *threshold* adaptif, *post-processing* morfologi), serta mengeksplorasi pendekatan *supervised deep learning* (CNN) yang berpotensi meningkatkan *robustness* dan generalisasi klasifikasi pada kondisi dunia nyata.

UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih yang mendalam kepada Bapak Assoc. Prof. Dr. Agung Ramadhanu, S.Kom., M.Kom., MTA.,

CM.NLP selaku Dosen Pengampu. Penguasaan ilmu Bapak dalam bidang *Image Processing* dan *Machine Learning* telah memberikan arahan yang jelas dan solutif, sehingga proses penelitian hingga penulisan naskah ini dapat berjalan dengan lancar dan terarah.

DAFTAR PUSTAKA

- [1] Yuhandri, et al. "Pengenalan Teknologi Pengolahan Citra Digital." *Community Development Journal*, vol. 3, no. 2, 2022.
- [2] Feriska Amalia, V. & Dewi, R. "Penilaian Kesegaran Ikan dengan K-NN." *JATI*, vol. 8, no. 4, 2024.
- [3] Rosyadi, I. et al. "Penerapan Citra Berbasis K-Means untuk Deteksi Penyakit Bulai." *Just IT*, vol. 13, no. 3, 2023.
- [4] Aula, S. "Klasterisasi Pola Penjualan Pestisida Menggunakan K-Means." *DJIECHNO*, vol. 1, no. 1, 2021.
- [5] Gafari, A. & Ramadhanu, A. "Klasifikasi Citra Digital Batu Kerikil dan Batu Kali." *JATI*, vol. 9, no. 2, 2025.
- [6] Saputra, R. et al. "Klasifikasi Timun Segar dan Busuk Menggunakan K-Means." *Journal of Education Research*, vol. 5, no. 4, 2024.
- [7] Yolanda, et al. "Identifikasi Cerdas Apel Fuji dan Apel Hijau." *Journal of Education Research*, vol. 5, no. 3, 2024.
- [8] Sinaga, A. S. "Segmentasi Ruang Warna L*a*b*." *Jurnal Mantik Penusa*, vol. 3, no. 1, 2019.
- [9] Numaningsih, D. et al. "Identifikasi Citra Tanaman Obat dengan Euclidean Distance." *BITS*, vol. 3, no. 3, 2021.
- [10] Salsabila, A. et al. "Identifikasi Citra Bunga dengan KNN dan GLCM." *Technomedia Journal*, vol. 6, no. 1, 2021.
- [11] Yanti, R. et al. "Identifikasi Pisang Emas dan Pisang Kapas." *Journal of Education Research*, vol. 5, no. 4, 2024.