

Ekstraksi Fitur Geometris Untuk Klasifikasi Ikan Air Tawar Menggunakan KNN

^{1*}Ahmad Rizqul Mubarak, ²Ratih Kumalasari Niswatin, ³Danar Putra Pamungkas

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹dancellriko@gmail.com, ²ratih.workmail@gmail.com, ³danar@unpkediri.ac.id

Penulis Korespondens : Ahmad Rizqul Mubarak

Abstrak—Identifikasi varietas ikan secara manual sering kali terkendala oleh subjektivitas manusia dan durasi operasional yang lama. Penelitian ini bertujuan mengimplementasikan sistem klasifikasi morfologi ikan berbasis desktop dengan memanfaatkan algoritma *K-Nearest Neighbor* (KNN). Parameter penciri yang digunakan meliputi ekstraksi fitur geometris seperti luas, panjang, lebar, dan rasio aspek objek. Berdasarkan hasil pengujian terhadap tiga spesies ikan (Patin, Gurame, dan Bandeng), sistem mencapai performa optimal pada konfigurasi jumlah tetangga (*K*) sebesar 13 dengan metrik jarak *Manhattan*. Hasil evaluasi menunjukkan tingkat akurasi sebesar 81,95%, dengan nilai rata-rata *precision*, *recall*, dan *f1-score* yang konsisten di angka 0,82. Perangkat lunak berbasis desktop ini mampu menyediakan solusi praktis bagi sektor perikanan dalam melakukan otomatisasi pendataan jenis ikan secara lokal tanpa ketergantungan koneksi internet.

Kata Kunci— aplikasi dekstop, ekstraksi geometris, ikan, k-nearest neighbors

Abstract—Manual fish variety identification is often constrained by human subjectivity and lengthy operational durations. This study aims to implement a desktop-based fish morphology classification system utilizing the *K-Nearest Neighbor* (KNN) algorithm. The distinguishing parameters used include the extraction of geometric features such as area, length, width, and object aspect ratio. Based on experimental results on three fish species (Patin, Gurame, and Bandeng), the system achieved optimal performance at a neighbor configuration (*K*) of 13 using the *Manhattan* distance metric. Evaluation results demonstrate an accuracy rate of 81.95%, with macro and weighted averages for *precision*, *recall*, and *f1-score* consistently holding at 0.82. This desktop-based software delivers a practical solution for the aquaculture sector to automate fish type cataloging locally without relying on internet connectivity.

Keywords— dekstop application, geometric extraction, fish, k-nearest neighbors, morphology

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan dan visi komputer semenjak awal dekade ini berkembang dengan sangat pesat dan mulai diadopsi luas pada berbagai sektor krusial, termasuk bidang perikanan. Indonesia menyimpan potensi ekonomi yang besar pada komoditas perikanan air tawar. Kendati demikian, efisiensi produksi di tingkat pembudidaya sering kali terkendala oleh sistem sortasi dan penentuan varietas yang masih dikerjakan secara konvensional. Penilaian berbasis pengamatan visual manusia memiliki batas kapabilitas, membutuhkan durasi operasional yang lama, serta rentan terhadap kesalahan (*human error*) akibat kelelahan fisik. Dampak dari ketidakpastian ini berujung pada kekeliruan pemisahan ukuran ataupun pendataan distribusi, yang lambat laun menurunkan standar mutu hasil perikanan.

Penelitian mengenai klasifikasi komoditas perikanan menggunakan kecerdasan buatan terus berkembang secara masif. Sihombing dkk. [1] menerapkan algoritma *K-Nearest Neighbor* (KNN) untuk mengklasifikasikan kelas ikan berdasarkan parameter ukuran fisik dan corak warna luar objek. Kombinasi metode ketetangaan KNN dan analisis tekstur berbasis *Gray Level Co-occurrence Matrix* (GLCM) juga diimplementasikan oleh Akbar dkk. [2] untuk mengidentifikasi varietas ikan air tawar secara optimal. Selain varietas spesies, pengolahan citra digital dengan segmentasi histogram biner otomatis juga terbukti andal untuk mendukung sistem pengenalan pola dasar morfologi objek fisis, seperti yang diuraikan oleh Radillah dkk. [3]. Karakteristik algoritma KNN yang efisien dan tangguh dalam menangani data multi-kelas berskala besar juga dikonfirmasi melalui pemetaan sebaran data multi-label oleh Fauzi dkk. [4]. Di samping itu, integrasi GLCM dan KNN juga efektif digunakan untuk menentukan tingkat kualitas kesegaran maupun standarisasi sortasi bahan pangan laut berdasarkan fitur visual luar [5].

Akurasi pemodelan KNN pada komoditas perikanan air tawar juga dipengaruhi oleh pemilihan bagian organ ikan yang menjadi representasi objek tangkapan, seperti pemanfaatan area mata ikan oleh Khamilah dan Hardjianto [6]. Pemanfaatan algoritma KNN juga terbukti andal untuk mengidentifikasi ketersediaan jenis komoditas konsumsi yang aman bagi kebutuhan gizi harian masyarakat [7]. Untuk memperoleh performa pengenalan yang stabil, Jerandu dkk. [8] menyarankan optimalisasi nilai ambang warna melalui ekstraksi nilai *Hue*, *Saturation*, dan *Value* (HSV) selain fitur warna dasar. Keunggulan komparatif pemodelan berbasis data KNN juga memperlihatkan efisiensi waktu komputasi yang lebih responsif jika dibandingkan dengan arsitektur *deep learning* yang kompleks pada skenario data latih berspesifikasi standar [9]. Kerangka pemrosesan awal seperti operasi pemotongan kontur citra (*cropping*) serta penyetaraan ruang warna biner bertindak sebagai fondasi utama sebelum matriks spasial dieksekusi oleh fungsi penentu jarak ketetangaan [10].

Menilik jajaran penelitian terdahulu tersebut, terdapat ruang pembaruan (*gap analysis*) yang berfokus pada penyusunan perangkat lunak mandiri yang praktis dioperasikan tanpa ketergantungan koneksi jaringan internet luas (*cloud application*). Oleh sebab itu, riset ini diarahkan untuk mengimplementasikan algoritma KNN pada ekosistem aplikasi desktop dengan mengandalkan fitur morfometri geometri luar objek, nilai rata-rata warna, tekstur GLCM, dan Hu Moments. Pemilihan platform desktop bermaksud agar sistem ini tangguh digunakan pada komputer lokal di area kolam budidaya yang berada di wilayah minim sinyal komunikasi.

II. METODE

Eksperimen ini berjalan di atas koridor penelitian pengembangan perangkat lunak komputer (*development research*) dengan pendekatan eksperimental kuantitatif. Variabel bebas dalam sistem ini mencakup manipulasi besaran nilai konstanta tetangga (K) serta pemilihan metrik jarak ruang vektor. Sedangkan variabel terikatnya diukur dari tingkat ketepatan label prediksi serta kalkulasi laporan matriks performa sistem.

A. Subjek, Bahan, dan Alat Penelitian

Subjek utama dalam penelitian ini adalah karakteristik morfologi luar (morfometri), warna, serta tekstur permukaan dari komoditas perikanan. Bahan penelitian yang digunakan berupa kumpulan citra digital dari tiga varietas ikan air tawar, yaitu ikan patin, ikan gurame, dan ikan bandeng. Total data awal yang dikumpulkan berjumlah 1.362 berkas gambar murni. Pengujian keandalan model final divalidasi menggunakan 205 sampel data uji (*test set*) murni.

Infrastruktur komputasi atau alat penelitian yang digunakan selama eksperimen terbagi menjadi dua bagian utama, yaitu:

1. Perangkat Keras (*Hardware*): Menggunakan satu unit komputer laptop berspesifikasi standar dengan dukungan memori RAM berkapasitas 8 GB serta komponen prosesor tingkat menengah.
2. Perangkat Lunak (*Software*): Sistem operasi Windows bertindak sebagai landasan utama lingkungan kerja perangkat lokal. Penulisan skrip penataan data, pemrosesan citra digital, hingga pemodelan komputasi statistik dikerjakan pada lingkungan *Google Colaboratory* dan *Visual Studio Code* menggunakan bahasa pemrograman Python 3. Implementasinya didukung secara penuh oleh pustaka open-source penunjang seperti OpenCV, NumPy, Scikit-learn, Scikit-image (skimage), dan Joblib.

B. Tahapan *Preprocessing* Citra

Sebelum masuk ke tahap pengenalan pola, setiap berkas gambar mentah wajib melewati serangkaian proses standarisasi atau *preprocessing* citra di dalam sistem desktop untuk mereduksi komponen data yang tidak diperlukan. Tahapan tersebut meliputi:

1. Penyamaan Ukuran (*Image Resizing*): Mengubah dimensi resolusi gambar yang bervariasi menjadi ukuran baku 224×224 piksel menggunakan teknik interpolasi bilinear agar beban komputasi data matriks seragam.
2. Reduksi Warna (*Grayscale*): Mentransformasi tiga kanal warna RGB (Red, Green, Blue) menjadi satu kanal intensitas abu-abu melalui fungsi rumus luminans standar berikut:

$$Y = 0.299R + 0.587G + 0.114B \dots \dots \dots (1)$$

3. Penyaringan Derau (*Filtering*): Menghilangkan gangguan bintik cahaya acak di sekitar objek memanfaatkan skema filter spasial biner (*Median Filter*) demi menjaga kehalusan garis tepi objek ikan..
4. Segmentasi Otsu (*Thresholding*): Mengisolasi siluet tubuh ikan (sebagai latar depan) terhadap area latar belakang. Metode Otsu secara otomatis menentukan nilai ambang batas optimal untuk mengubah citra abu-abu menjadi representasi teks data matriks biner berupa angka hitam (0) dan putih (1)

C. Ekstraksi Fitur dan Model Statistik

Setelah citra biner terbentuk sempurna, proses dilanjutkan ke tahap ekstraksi fitur multi-dimensi untuk mengambil kombinasi karakteristik fisis, warna, dan tekstur dari objek ikan. Total fitur yang diekstrak oleh sistem berjumlah 21 fitur penciri, yang terdiri dari:

1. Fitur Morfometri Geometris: Meliputi rasio luas kontur (*area ratio*), rasio aspek (*aspect ratio*), *solidity*, dan *circularity*. Nilai *aspect ratio* didapatkan dari pembagian panjang horisontal maksimal (W) terhadap lebar vertikal maksimal (H) objek melalui rumus:

$$\text{Aspect Ratio} = \frac{W}{H} \dots \dots \dots (2)$$

Contoh perhitunganya:

- a. Sampel Ikan Patin (Bentuk Memanjang)
 Panjang horizontal (W) = 240 piksel
 Lebar vertikal (H) = 80 piksel
 Keterangan: Nilai yang besar (jauh di atas 1.00) membuktikan secara fisik bahwa ikan patin memiliki struktur tubuh yang pipih memanjang.
- b. Sampel Ikan Gurame (Bentuk Bundar/Pipih)
 Panjang horizontal (W) = 180 piksel
 Lebar vertikal (H) = 135 piksel
 Keterangan: Nilai yang mendekati angka 1.00 menandakan bahwa proporsi panjang dan lebar tubuh ikan gurame cenderung seimbang (berbentuk membulat).
- c. Sampel Ikan Bandeng (Bentuk Sedang/Torpedoid)
 Panjang horizontal (W) = 210 piksel
 Lebar vertikal (H) = 100 piksel
 Keterangan: Nilai 2.10 menjadi penciri fisik bagi ikan bandeng yang memiliki bentuk tubuh ideal/tengah-tengah (tidak terlalu memanjang seperti patin dan tidak melebar seperti gurame).

- 1) Sempel Ikan Patin

$$\text{Aspect Ratio}_{\text{Patin}} = \frac{240}{80 \text{ px}} = 3.00 \dots \dots \dots (3)$$

- 2) Sempel Ikan Gurami

$$\text{Aspect Ratio}_{\text{Gurame}} = \frac{180}{135 \text{ px}} = 1.33 \dots \dots \dots (4)$$

- 3) Sempel Ikan Bandeng

$$\text{Aspect Ratio}_{\text{Bandeng}} = \frac{210}{100 \text{ px}} = 2.10 \dots \dots \dots (5)$$

2. Fitur Warna: Mengambil nilai rata-rata intensitas piksel (*mean color*) pada 3 kanal warna BGR (Blue, Green, Red) dan 3 kanal ruang warna HSV (Hue, Saturation, Value).

Contoh perhitunganya:

- a. Ruang Warna BGR (Skala 0–255)
 Kanal Blue (B): $B = [120, 130, 125, 140, 135]$
 Kanal Green (G): $G = [90, 95, 100, 85, 90]$
 Kanal Red (R): $R = [60, 65, 55, 70, 60]$
 Perhitungan Rata-rata (*Mean Color*):

$$\mu_B = \frac{120+130+125+140+135}{5} = \frac{650}{5} = 130.00 \dots \dots \dots (6)$$

$$\mu_G = \frac{90+95+100+85+90}{5} = \frac{460}{5} = 92.00 \dots \dots \dots (7)$$

$$\mu_R = \frac{60+65+55+70+60}{5} = \frac{310}{5} = 62.00 \dots \dots \dots (8)$$

- b. Ruang Warna HSV (Setelah Dikonversi dari RGB)
 Kanal Hue (H): $H = [12, 14, 10, 15, 11]$ (*Menunjukkan jenis warna/corak pigmen*)
 Kanal Saturation (S): $S = [150, 160, 155, 145, 150]$ (*Menunjukkan kepekatan warna*)

Kanal Value (V): $V = [200, 210, 205, 195, 200]$ (Menunjukkan tingkat kecerahan objek)

$$\mu_H = \frac{12+14+10+15+11}{5} = \frac{62}{5} = 12.40 \dots \dots \dots (9)$$

$$\mu_S = \frac{150+160+155+145+150}{5} = \frac{760}{5} = 152.00 \dots \dots \dots (10)$$

$$\mu_V = \frac{200+210+205+195+200}{5} = \frac{1010}{5} = 202.00 \dots \dots \dots (11)$$

Keterangan bagi Model KNN: Nilai $\mu_V = 202.00$ yang tinggi ini secara fisik menggambarkan objek ikan yang dominan berwarna putih mengkilap atau keperakan cerah, yang menjadi ciri khas permukaan kulit Ikan Patin.

3. Fitur Tekstur GLCM: Nilai *contrast*, *homogeneity*, *energy*, dan *correlation* yang dihitung dari *Gray Level Co-occurrence Matrix* pada sudut spasial tertentu.

Contoh perhitungannya:

Matriks Citra Input (3×3)

$$\text{Citra} = \begin{bmatrix} 0 & 1 & 1 \\ 0 & 0 & 1 \\ 1 & 1 & 0 \end{bmatrix} \dots \dots \dots (12)$$

Kita hitung Matriks Kookurensi (GLCM) untuk hubungan spasial jarak $d = 1$ dan sudut orientasi $\theta = 0^\circ$ (horizontal ke kanan). Kita cari berapa kali pasangan nilai piksel tetangga (i,j) muncul berdampingan:

Pasangan (0,0): muncul 1 kali (baris 2: dari kolom 1 ke kolom 2)

Pasangan (0,1): muncul 2 kali (baris 1: kol 1 ke kol 2; baris 2: kol 2 ke kol 3)

Pasangan (1,0): muncul 1 kali (baris 3: dari kolom 2 ke kolom 3)

Pasangan (1,1): muncul 2 kali (baris 1: kol 2 ke kol 3; baris 3: kol 1 ke kol 2)

Total kemunculan pasangan piksel (*sum*) = $1 + 2 + 1 + 2 = 6$.

4. Hu Moments: 7 nilai momen invariant untuk menangkap karakteristik bentuk objek secara konsisten meskipun terjadi rotasi atau perubahan skala.

Seluruh matriks fitur mentah tersebut dikelola ke dalam sebuah skema *Pipeline* dan disetarakan skalanya menggunakan metode statistika **StandardScaler** untuk mentransformasikan sebaran data agar memiliki rata-rata (*mean*) sama dengan 0 dan varians sebesar 1 melalui rumus:

$$X_{\text{norm}} = \frac{X - \mu}{\sigma} \dots \dots \dots (13)$$

Contoh Kasus Perhitungan

Data Uji Baru (X_{baru}): [2.20, 110.0]

Data Latih 1 (Patin): [3.00, 180.0]

Data Latih 2 (Gurame): [1.33, 50.0]

Data Latih 3 (Bandeng): [2.10, 120.0]

- a. Langkah 1 standardisasi Fitur (*StandardScaler*)

Fitur 1 (Aspect Ratio): Rata-rata (μ_1) = 2.00; Standar Deviasi (σ_1) = 0.50.....(14)

Fitur 2 (Mean Value): Rata-rata (μ_2) = 100.0; Standar Deviasi (σ_2) = 40.0.....(15)

Kita transformasikan nilai pada Data Uji Baru (X_{baru}) menggunakan rumus:

$$X_{\text{norm}} = \frac{X - \mu}{\sigma} \quad (16)$$

$$X_{1\text{norm}} = \frac{2.20 - 2.00}{0.50} = 0.40 \quad (17)$$

$$X_{2\text{norm}} = \frac{110.0 - 100.0}{40.0} = 0.25 \quad (18)$$

$$\text{Vektor terstandarisasi data uji: } X_{\text{baru norm}} = [0.40, 0.25]$$

Dengan rumus yang sama, berikut adalah hasil transformasi untuk ke-3 data latih:

$$\text{Vektor Terstandarisasi Patin } (Y_{\text{Patin}}) = [2.00, 2.00] \quad (19)$$

$$\text{Vektor Terstandarisasi Gurame } (Y_{\text{Gurame}}) = [-1.34, -1.25] \quad (20)$$

$$\text{Vektor Terstandarisasi Bandeng } (Y_{\text{Bandeng}}) = [0.20, 0.50] \quad (21)$$

Model statistik yang digunakan untuk mengambil keputusan klasifikasi adalah algoritma *K-Nearest Neighbor* (KNN). Proses pencarian parameter terbaik dioptimalkan menggunakan fungsi *GridSearchCV* dengan skema *5-fold cross-validation*. Berdasarkan hasil penalaan parameter, rumus statistik yang diimplementasikan pada model ini didasarkan pada metrik Jarak Manhattan (*City Block Distance*) sebagai berikut:

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

b. Langkah 2: Menghitung Jarak Kedekatan (*Jarak Manhattan*)

Aplikasi desktop menghitung jarak kota blok antara data uji terhadap 3 data latih menggunakan rumus:

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (23)$$

Jarak ke Data Latih Patin:

$$d(X, Y_{\text{Patin}}) = |0.40 - 2.00| + |0.25 - 2.00| = 1.60 + 1.75 = 3.35 \quad (24)$$

Jarak ke Data Latih Gurame:

$$d(X, Y_{\text{Gurame}}) = |0.40 - (-1.34)| + |0.25 - (-1.25)| = 1.74 + 1.50 = 3.24 \quad (25)$$

Jarak ke Data Latih Bandeng:

$$d(X, Y_{\text{Bandeng}}) = |0.40 - 0.20| + |0.25 - 0.50| = 0.20 + 0.25 = 0.4 \quad (26)$$

c. Langkah 3: Keputusan Klasifikasi

Karena konfigurasi model menggunakan pembobotan berbasis kebalikan jarak (weights : distance), nilai bobot voting (w) untuk tiap kelas dihitung melalui rumus $w = \frac{1}{d}$

$$\text{Bobot Voting Patin } (w_{\text{Patin}}) = \frac{1}{3.35} = 0.298 \quad (27)$$

$$\text{Bobot Voting Gurame } (w_{\text{Gurame}}) = \frac{1}{3,24} = 0.308 \quad (28)$$

$$\text{Bobot Voting Bandeng } (w_{\text{Bandeng}}) = \frac{1}{0,45} = 2.222 \quad (29)$$

Hasil Akhir Keputusan: Nilai bobot Bandeng (2.222) jauh lebih besar daripada Patin dan Gurame karena jarak vektor fiturnya paling dekat dengan data uji. Maka, dalam pencarian tetangga terdekat ($K=13$), sistem secara mutlak mendeteksi objek sebagai BANDENG.

III. HASIL DAN PEMBAHASAN

Sistem komputer lokal berbasis desktop yang mengimplementasikan metode *K-Nearest Neighbor* (KNN) untuk klasifikasi tiga multi-kelas spesies ikan air tawar telah berhasil dikembangkan dan dievaluasi. Proses pengujian dilakukan melalui dua skema utama, yaitu pengujian performa model klasifikasi menggunakan matriks evaluasi standar komputasi dan pengujian fungsionalitas antarmuka grafis pengguna (*Graphical User Interface*).


A. Hasil Optimasi Hyperparameter Model

Proses pencarian parameter optimal (*hyperparameter tuning*) menggunakan fungsi GridSearchCV dengan skema *5-fold cross-validation* berhasil memetakan kombinasi terbaik untuk arsitektur model KNN. Berdasarkan running log program, konfigurasi terbaik yang terpilih secara otomatis adalah metrik jarak *Manhattan*, penetapan jumlah tetangga terdekat (K) sebanyak 13 (`n_neighbors: 13`), serta implementasi pembobotan berbasis kebalikan jarak (`weights: distance`).

Kombinasi parameter komputasi ini berhasil memberikan nilai akurasi rata-rata pada fase data validasi sebesar 82,44% dan mencatatkan skor akurasi final sebesar 81,95% ketika diuji langsung menggunakan 205 sampel data uji murni yang belum pernah dikenali oleh model sebelumnya (*unseen data test*).

B. Analisis *Confusion Matrix* dan Klasifikasi Per Kelas

Untuk memetakan distribusi akurasi prediksi maupun letak kekeliruan klasifikasi model secara mendalam pada tiap-tiap kelas (Bandeng, Gurame, dan Patin), dijalankan pengujian evaluasi visual berbasis grafik *Confusion Matrix* yang disajikan pada Gambar 1.



Gambar 1. Grafik *Confusion Matrix* Pengujian Multi-Kelas Model KNN

Berdasarkan visualisasi matriks kebingungan pada Gambar 1, sebaran prediksi data aktual terhadap label prediksi sistem dapat dijabarkan secara detail sebagai berikut:

1. Kelas Ikan Bandeng: Dari total 69 sampel gambar aktual ikan bandeng, sistem berhasil memprediksi secara tepat sebanyak 53 sampel. Sebanyak 14 sampel terdeteksi keliru sebagai ikan gurame, dan 2 sampel salah diklasifikasikan sebagai ikan patin.
2. Kelas Ikan Gurame: Dari total 68 sampel gambar aktual ikan gurame, sistem mencatatkan tingkat keandalan mendeteksi objek aktual paling tinggi dengan keberhasilan memprediksi secara tepat sebanyak 59 sampel. Sisanya, sebanyak 9 sampel terdeteksi keliru sebagai ikan bandeng, dan tidak ada satu pun sampel yang meleset ke kelas ikan patin (0 sampel).
3. Kelas Ikan Patin: Dari total 68 sampel gambar aktual ikan patin, model berhasil mengklasifikasikan secara valid sebanyak 56 sampel objek secara tepat. Sebanyak 9 sampel teridentifikasi keliru sebagai ikan bandeng, dan 3 sampel meleset masuk ke dalam kelas ikan gurame.

Hasil tabulasi grafik tersebut dikonversikan ke dalam metrik penilaian *Classification Report* ilmiah untuk menghitung performa nilai *precision*, *recall*, dan *f1-score* secara presisi pada Tabel 1.

Tabel 1. Laporan Klasifikasi (*Classification Report*) Pengujian Multi-Kelas Model KNN

Kelas Objek	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i> (data Uji)
Ikan Bandeng	0,85	0,77	0,81	69
Ikan Gurami	0,77	0,87	0,81	68
Ikan Patin	0,85	0,82	0,84	68
Akurasi	81,95%	82	0,82	205
Rata-rata Makro	0,82	0,82	0,82	205
Rata-rata Berbobot	0,82	0,82	0,82	205

Berdasarkan data Tabel 1, analisis komparasi komputasi dapat ditarik benang merahnya. Spesies ikan patin mendapatkan capaian f1-score paling tinggi yaitu 0,84 karena struktur bentuk tubuhnya yang cenderung memanjang memiliki nilai momen invariant (Hu Moments) yang sangat kontras jika dibandingkan dengan tubuh ikan gurame yang pipih bundar. Kesalahan minor (misklasifikasi) antara ikan bandeng dan ikan gurame dipengaruhi oleh faktor kemiripan tekstur bersisik halus pada jarak spasial GLCM tertentu serta intensitas persebaran warna biner latar depan saat segmentasi Otsu bekerja pada kondisi sudut pencahayaan gambar tangkapan yang kurang merata.

IV. KESIMPULAN

Penelitian ini berhasil membuktikan bahwa implementasi ekstraksi fitur multi-dimensi (morfometri, warna, tekstur GLCM, dan Hu Moments) terbukti sangat efektif untuk mendukung klasifikasi jenis ikan menggunakan metode KNN pada platform aplikasi desktop. Sistem komputer lokal ini mampu menyuguhkan jawaban instan terhadap penentuan varietas spesies tanpa memerlukan proses komputasi awan yang kompleks. Keandalan model yang teruji lewat nilai akurasi mencapai 81,95% melalui optimasi parameter Jarak Manhattan dengan batas $K=13$ menegaskan bahwa rancangan program ini layak diaplikasikan sebagai instrumen pendukung digitalisasi sortasi pada sektor budidaya perikanan. Saran untuk pengembangan ke depan adalah penambahan segmentasi berbasis *deep learning* guna meningkatkan ketajaman pemisahan kontur pada kondisi pencahayaan luar ruangan yang ekstrem.

DAFTAR PUSTAKA

- [1] A. Rahma, D. Sihombing, I. M. Herawati, N. H. Lubis, and W. Aprizal, "Jurnal Sistem dan Teknologi Informasi Indonesia Klasifikasi Harga Ikan Koi Berdasarkan Jumlah Corak dan Ukuran Menggunakan Algoritma K-Nearest Neighbor Classification of Koi Fish Price Based on Number of Patterns and Size Using K- Nearest Neighbor Algorit," vol. 10, no. 1, pp. 1–8, 2025.
- [2] and R. K. N. M. A. D. Akbar, A. B. Setiawan, "Klasifikasi Jenis Ikan Cupang Menggunakan Metode GLCM Dan KNN Mohamad," pp. 152–158, 2021.
- [3] and I. F. T. Radillah, K. Ameliza, "Segmentasi Citra Menggunakan Metode Otsu dalam Pengenalan Pola Sederhana Teuku," *Indones. J. Comput. Sci.*, vol. 12, no. 2, pp. 284–301, 2023, [Online]. Available: <http://ijcs.stmikindonesia.ac.id/ijcs/index.php/ijcs/article/view/3135>
- [4] M. R. Fauzi, R. A. Pratama, P. Laksono, and P. Eosina, "Penerapan Big Data Menggunakan Algoritma Multi-Label K-Nearest Neighbor dalam Analisis Sentimen Konsumen UMKM Sektor Kuliner," *Krea-TIF*, vol. 9, no. 1, p. 9, 2021, doi: 10.32832/kreatif.v9i1.3587.
- [5] N. Umar, F. Haikal, and M. Razak, "Citra Digital Untuk Klasifikasi Kualitas Udang Windu Menggunakan Algoritma GLCM dan K-Nearest Neighbor," *J. Inform.*, vol. 9, no. 2, pp. 93–102, 2022, doi: 10.31294/inf.v9i2.13686.
- [6] H. Khamilah and M. Hardjianto, "Pengklasifikasian Kualitas Ikan Nila Berbasis Mata Ikan Dengan Metode K- Nearest Neighbors (K-Nn) Classification of Nile Tilapia Quality Based on Fish Eye Using the K-Nearest Neighbors (K-Nn) Method," vol. 3, no. September, pp. 539–546, 2024.
- [7] M. Jannah, A. A. Nababan, and Y. S. Ningsi, "Penerapan Metode K-Nearest Neighbor Dalam Identifikasi Jenis Ikan Salmon Yang Dapat Dikomsumsi Untuk Bahan Mpasi Bayi," *J-SISKO TECH (Jurnal Teknol. Sist. Inf. dan Sist. Komput. TGD)*, vol. 6, no. 2, p. 636, 2023, doi: 10.53513/jsk.v6i2.8716.
- [8] 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, 2022, doi: 10.47065/bits.v4i3.2613.
- [9] N. Abdurrahman, B. Rahmat, and A. N. Sihananto, "Perbandingan Performa Klasifikasi Citra Ikan Menggunakan Metode K-Nearest Neighbor (K-NN) Dan Convolutional Neural Network (CNN)," *J. Sist. Inf. dan Inform.*, vol. 2, no. 2, pp. 84–93, 2023, doi: 10.33379/jusifor.v2i2.3728.
- [10] I. E. Hasym and I. Susilawati, "Konvergensi Teknologi dan Sistem Informasi Klasifikasi Jenis Ikan Cupang Menggunakan Algoritma Principal Component Analysis (PCA) Dan K-Nearest Neighbors (KNN)," *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, pp. 168–179, 2021.