

Deteksi Kesegaran Ikan Kembung dengan Metode KNN Berdasarkan Fitur GLCM dan RGB-HSV

Januwa Putra Wiastopo^{1*}, Imelda Imelda²

^{1,2} Fakultas Teknologi Informasi, Teknik Informatika, Universitas Budi Luhur, Jakarta, Indonesia
Jl. Ciledug Raya, RT.10/RW.2, Petukangan Utara, Kec. Pesanggrahan, Jakarta Selatan 12260
E-mail: ¹*2011500390@student.budiluhur.ac.id, ²imelda@budiluhur.ac.id

(*: corresponding author)

Abstrak—Ikan kembung, yang memiliki nilai gizi tinggi dan permintaan konsumen yang terus meningkat, sering kali mengalami penurunan kualitas akibat proses degradasi setelah penangkapan. Penurunan ini tidak hanya mengurangi nilai gizi tetapi juga dapat membuat ikan kembung menjadi beracun jika dikonsumsi dalam keadaan busuk. Meskipun metode tradisional seperti analisa mikroskopis dan kimia dapat digunakan untuk menilai kesegaran ikan, metode ini tidak efisien karena memerlukan waktu, biaya, dan tenaga yang besar. Untuk mengatasi masalah ini, penelitian ini mengimplementasikan sistem deteksi kesegaran ikan kembung dengan metode *K-Nearest Neighbors* (KNN). Sistem ini menggunakan fitur warna RGB-HSV dan tekstur GLCM dari citra ikan kembung untuk membedakan antara ikan kembung segar dan busuk. *Dataset* yang digunakan terdiri dari 700 citra ikan kembung, yang dibagi menjadi data pelatihan dan pengujian. Tujuan dari penelitian ini adalah untuk menyediakan alat yang mudah digunakan oleh penjual dan pembeli ikan kembung dalam menentukan kesegaran ikan dengan lebih akurat dan efisien. Hasil penelitian menggunakan normalisasi dengan akurasi 96%, presisi 96% dan recall 96%, menunjukkan bahwa pendekatan berbasis KNN dengan fitur warna dan tekstur dapat secara efektif mendeteksi kesegaran ikan kembung, memberikan solusi yang lebih akurat dibandingkan metode tradisional. Pendekatan ini memberikan kontribusi signifikan dalam proses penentuan kesegaran ikan kembung, membantu mengurangi kesalahan dalam pemilihan ikan kembung oleh konsumen.

Kata Kunci— Deteksi, GLCM, HSV, Ikan Kembung, KNN

Abstract—Mackerel, which has high nutritional value and increasing consumer demand, often experiences a decline in quality due to the degradation process after being caught. This decline not only reduces its nutritional value but can also make mackerel toxic if consumed when spoiled. Although traditional methods such as microscopic and chemical analysis can be used to assess fish freshness, these methods are inefficient as they require significant time, cost, and labor. To address this issue, this study implements a mackerel freshness detection system using the *K-Nearest Neighbors* (KNN) method. This system utilizes RGB-HSV color features and GLCM texture features from mackerel images to distinguish between fresh and spoiled mackerel. The dataset used consists of 700 mackerel images, which are divided into training and testing data. The aim of this study is to provide a tool that can be easily used by mackerel sellers and buyers to determine the freshness of the fish more accurately and efficiently. The results of the study, using normalization, achieved 96% accuracy, 96% precision, and 96% recall, indicating that the KNN-based approach with color and

texture features can effectively detect mackerel freshness, offering a more accurate solution compared to traditional methods. This approach significantly contributes to the process of determining mackerel freshness, helping to reduce errors in selecting fresh mackerel by consumers.

Keyword— Detection, GLCM, HSV, KNN, Mackerel

I. PENDAHULUAN

Manusia merupakan makhluk cerdas yang senantiasa meningkatkan keterampilannya untuk memudahkan segala aktivitas. Berbagai percobaan dilakukan untuk menciptakan teknik yang efisien. Dengan semakin pesatnya perkembangan teknologi, salah satunya adalah pengolahan citra. Pengolahan citra memberikan informasi yang berguna bagi pengguna[1].

Ikan kembung adalah kelompok ikan epipelagis dan neritic di daerah pantai dan laut. Nelayan terus menangkap ikan ini untuk memenuhi permintaan konsumen domestik yang meningkat karena nilai gizinya yang tinggi dan nilai ekonomisnya yang menengah[2]. Menurut data awal dari Kementerian Kelautan dan Perikanan (KKP), konsumsi ikan nasional di 34 provinsi mencapai 55,95 kg per kapita per tahun. Angka ini melampaui target nasional tahun 2023 dan menunjukkan peningkatan dibandingkan dengan konsumsi tahun 2022 yang sebesar 56,48 kg per kapita. KKP menargetkan peningkatan konsumsi ikan nasional menjadi 62,05 kg per kapita per tahun pada tahun 2024[3].

Kesegaran ikan kembung diperiksa dengan analisa mikroskopis dan kimia. Namun, karena memerlukan banyak tenaga kerja, menghabiskan banyak uang, dan memerlukan waktu yang lama, metode ini tidak efektif [4]. Oleh karena itu, peneliti menggunakan metode KNN, yang didasarkan pada parameter tubuh dan warna mata ikan, untuk menentukan kesegaran ikan kembung.

Setelah ditangkap atau dipanen, ikan kembung mengalami sejumlah proses degradasi yang mengakibatkan penurunan kualitas. Penurunan ini terutama disebabkan oleh masuknya bakteri. Akibat dari penurunan kualitas tersebut, kandungan gizi ikan berkurang, dan jika sudah membusuk, ikan dapat menjadi beracun. Penurunan kualitas ikan dapat dilihat dari perubahan pada kulit, warna mata, insang, tekstur, dan bau ikan. Sebelum mengkonsumsi ikan, konsumen biasanya memilih ikan yang masih segar atau dalam kondisi baik. Umumnya, konsumen menilai kesegaran ikan kembung secara manual dengan memeriksa warna mata, kekencangan daging,

dan bau ikan. Namun, seringkali terjadi kesalahan dalam memilih ikan kembung yang segar [5].

Banyak penelitian mengenai kesegaran ikan. Ada yang meneliti mengenai kesegaran ikan tongkol. Metode penelitiannya yang menggunakan metode Binary Similarity dilakukan oleh Fitriyah dkk.,[6] dengan memanfaatkan ekstraksi fitur RGB. Penelitian ini berhasil mengklasifikasi kesegaran ikan dan mencapai akurasi hingga 60%. Sebuah penelitian lain telah dilakukan oleh Sarimin dkk.,[7] penelitian ini berfokus pada deteksi kesegaran ikan bawal. Dalam penelitian ini menerapkan metode K-Means dengan menggunakan ekstraksi fitur GLCM dan HSV dengan akurasi mencapai 50%. Penelitian terbaru lainnya dilakukan oleh Lamasigi dkk.,[8] tentang sistem klasifikasi ikan tuna menggunakan metode K-Nearest Neighbor dengan memanfaatkan ekstraksi fitur tekstur GLCM, akurasi klasifikasi K-NN didapat dengan rata-rata akurasi 50%.

Dalam penelitian ini mengimplementasi metode KNN berdasarkan fitur tekstur GLCM dan warna RGB-HSV dalam mendeteksi kesegaran ikan kembung. Penelitian ini bertujuan untuk mengembangkan sistem deteksi kesegaran ikan kembung yang mudah digunakan dan dipahami oleh masyarakat, terutama bagi para penjual dan pembeli ikan kembung. Penjual dapat menggunakan hasil penelitian ini untuk menentukan kesegaran ikan kembung yang mereka jual, sedangkan pembeli dapat menggunakannya untuk memilih ikan kembung yang segar. Solusi penelitian ini mendeteksi kesegaran ikan kembung menggunakan fitur warna RGB-HSV dan fitur tekstur GLCM dengan KNN. Penelitian ini menekankan pentingnya peran teknologi dalam membantu apa yang ingin disampaikan oleh para pemangku kepentingan di industri perikanan, seperti nelayan, pedagang ikan, dan konsumen, untuk mendapatkan informasi yang akurat tentang kesegaran ikan kembung. Hal ini memudahkan pemahaman bagi kedua pihak.

Dengan demikian, penelitian ini diharapkan dapat bermanfaat untuk menilai kesegaran ikan kembung. kapanpun dan dimanapun, juga diharapkan dapat membantu masyarakat mengetahui kesegaran ikan dan mengurangi risiko keracunan sehingga dapat membantu lebih banyak lagi masyarakat mendapatkan kesegaran ikan kembung yang tepat.

II. METODE PENELITIAN

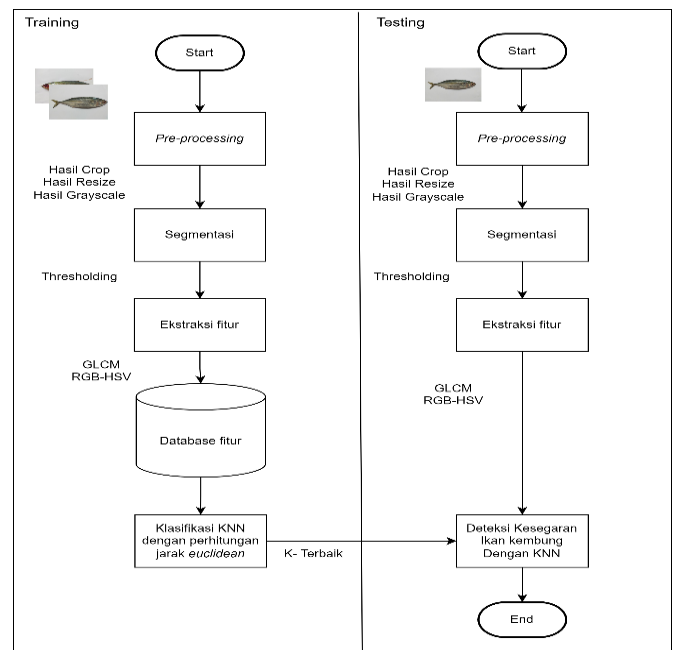
A. Data Penelitian

Data penelitian ini diperoleh melalui pengambilan gambar langsung dengan menggunakan kamera *smartphone* dengan resolusi 48 MP. Resolusi tinggi ini dipilih untuk menangkap detail tekstur dan warna ikan kembung secara lebih akurat, terutama pada bagian mata dan badan yang menjadi indikator utama kesegaran. Format .jpg dipilih karena mampu menghasilkan kompresi yang baik tanpa terlalu mengorbankan kualitas gambar. Seluruh citra yang digunakan memiliki resolusi 1280 x 720 piksel. Rasio aspek 3:4 dipertahankan untuk menjaga proporsi asli ikan kembung dalam citra. *Dataset* yang telah dikumpulkan berjumlah 600 citra, terbagi secara merata menjadi dua kelas yaitu ikan kembung segar dan ikan kembung busuk, masing-masing sebanyak 300 citra. Jumlah data ini dinilai cukup representatif untuk melatih model

klasifikasi. Untuk mengevaluasi kinerja model, digunakan *dataset* uji yang terpisah berjumlah 100 citra. Data uji ini diperoleh dengan cara yang sama seperti *dataset* pelatihan. Dengan membandingkan hasil prediksi model dengan label sebenarnya.

B. Penerapan Metode

Dalam proses mengembangkan sistem aplikasi yang menggunakan algoritma KNN untuk mendeteksi kesegaran ikan kembung, ada proses yang harus diikuti agar implementasi penelitian ini berjalan dengan baik. Tujuan penggunaan metode penelitian ini adalah untuk memberikan gambaran menyeluruh tentang proses atau alur aplikasi dari awal hingga akhir, seperti yang ditunjukkan pada Gambar 1.



Gambar 1. Proses Penerapan Metode

C. Pengumpulan Data

Pada penelitian ini berupa kumpulan citra ikan kembung, *dataset* penelitian ini bersumber dari pengambilan gambar secara manual dengan menggunakan *smartphone* dengan resolusi 48MP dan rasio 4:3. Data yang dikumpulkan oleh penelitian ini terdiri dari 700 citra ikan kembung. Citra tersebut akan dibagi menjadi dua bagian: satu untuk data pelatihan yang terdiri dari 600 citra, dan satu lagi untuk data pengujian yang terdiri dari 100 citra. Perbedaan antara citra ikan kembung segar dan busuk dapat dilihat dari beberapa aspek visual yang menjadi ciri khas keduanya. Ikan kembung segar memiliki warna kulit yang cerah dan mengkilap, dengan sisik yang menempel kuat, matanya jernih, menonjol, dan cerah, tekstur badan pada ikan kembung segar tampak elastis dan kenyal, sebaliknya, ikan kembung yang busuk menunjukkan tanda-tanda degradasi seperti warna kulit yang kusam dan pudar, serta sisik yang mulai lepas, matanya suram, datar, dengan tekstur daging yang lembek dan perut yang mungkin kembung atau robek. Sampel dari *dataset* ikan kembung dapat dilihat pada Gambar 2.



Gambar 2. Sampel Dataset Ikan Kembung

D. Pre-processing Data


Proses *pre-processing data* ini bertujuan untuk meningkatkan hasil pelatihan dan dapat meningkatkan akurasi pengujian. Berikut adalah tahapan *preprocessing* yang dilakukan dalam penelitian:

1) *Cropping Citra*: Proses pemotongan gambar, juga dikenal sebagai "*cropping*", memfokuskan pada elemen utama gambar, yaitu ikan kembung, dengan menghilangkan bagian yang tidak penting. Untuk penelitian ini, pemotongan dilakukan secara manual menggunakan program yang sudah dibuat pada kumpulan data, dan dipilih khusus untuk menunjukkan ikan kembung sebagai elemen utama [9]. Gambar 3 adalah proses *cropping* citra.




Gambar 3. Proses Cropping Citra

2) *Resize Citra*: *Resize* citra adalah sebuah proses untuk mengubah ukuran dimensi citra dengan memperkecil atau memperbesar citra sesuai kebutuhan. Dalam penelitian ini citra ikan kembung di-*resize* ke ukuran 640*640 piksel. *Resizing* gambar digunakan untuk mempercepat proses pelatihan dan pengujian sistem serta menjaga konsistensi ukuran citra [10]. Gambar 4 adalah proses *resize* citra.



Gambar 4. Proses Resize Citra

3) *Grayscale Citra*: Citra *grayscale* adalah citra yang hanya terdiri dari berbagai nuansa abu-abu. Penggunaan citra *brightness grayscale* digunakan sebagai variasi gelap terang terhadap citra agar model bisa lebih baik dalam pembelajarannya saat tahap *training* [11]. Gambar 5 merupakan hasil citra *Grayscale*.




Gambar 5. Proses Grayscale Citra

E. Segmentasi Citra

Proses mengidentifikasi dan membedakan objek atau bagian tertentu dari gambar dengan nilai atau fitur yang berbeda dikenal sebagai segmentasi. Berikut adalah langkah-langkah segmentasi pada penelitian ini:

1) *Thresholding Citra*: Pada proses ini, citra diubah menjadi gambar biner, di mana setiap piksel citra akan diberi nilai 0 atau 1, Proses *Thresholding* gambar dilakukan dengan mengubah gambar RGB menjadi gambar *grayscale*, lalu mengubah gambar *grayscale* tersebut menjadi gambar biner berdasarkan intensitas ambang piksel. *Thresholding* citra dapat digunakan untuk memisahkan objek dari latar belakang atau memisahkan beberapa bagian dari citra berdasarkan tingkat kecerahannya (intensitas) [12]. Proses *Thresholding* Citra dapat ditunjukkan pada Gambar 6.



Gambar 6. Proses Thresholding Citra

F. Ekstraksi Fitur

Ekstraksi fitur melibatkan pengambilan informasi penting dari citra. Data ini akan digunakan sebagai parameter atau nilai input untuk deteksi. Penelitian ini menggunakan dua jenis ekstraksi ciri: tekstur dan warna. Metode ekstraksi ciri yang diterapkan meliputi:

1) *Ekstraksi Ciri Ruang Warna RGB*: Ruang warna RGB adalah model yang merepresentasikan warna dengan menggunakan merah, hijau, dan biru. Model ini beroperasi pada skala dari 0 hingga 255. Warna setiap piksel ditentukan oleh kombinasi intensitas Merah (R), Hijau (G), dan Biru (B) pada lokasi piksel tertentu [13]. Ruang warna RGB dapat ditentukan dengan persamaan berikut:

$$R = \frac{R}{(R + G + B)} \quad (1)$$

$$G = \frac{G}{(R + G + B)} \quad (2)$$

$$B = \frac{B}{(R + G + B)} \quad (3)$$

2) *Ekstraksi Ciri Ruang Warna HSV*: Ruang warna HSV memisahkan komponen warna menjadi Hue (H), *Saturation* (S), dan *Value* (V). Ruang warna ini lebih mudah digunakan

untuk mendeskripsikan warna dibandingkan dengan ruang warna RGB [13]. Transformasi dari ruang warna RGB ke HSV dapat dihitung menggunakan rumus berikut:

$$V = \max(R, G, B) \quad (4)$$

$$S = \begin{cases} 0 & , \text{jika } V = 0 \\ 1 - \frac{\min(R, G, B)}{V} & , \text{jika } V > 0 \end{cases} \quad (5)$$

$$H = \begin{cases} 0 & , \text{jika } V = 0 \\ \frac{60 * (G - B)}{S * V} & , \text{jika } V = R \\ 60 * \left[2 + \frac{B - R}{S * V} \right] & , \text{jika } V = G \\ 60 * \left[2 + \frac{R - G}{S * V} \right] & , \text{jika } V = B \end{cases} \quad (6)$$

$$H = H + 360, \text{jika } H < 0 \quad (7)$$

3) *Ekstraksi Ciri Tekstur GLCM*: GLCM berfungsi dengan membuat matriks *co-occurrence* yang mendefinisikan hubungan spasial antara piksel referensi dan piksel tetangganya berdasarkan sudut dan jarak d , dimana jarak d biasanya 1 dan diwakili oleh sudut 0° . Dengan menggunakan 7 satu piksel dalam 4 arah sudut diantaranya 0° , 45° , 90° dan 135° , fitur seperti disimilitas, energi, kontras, homogenitas, dan korelasi dapat diekstraksi dari GLCM [8]. Dalam penelitian ini ada 5 fitur ekstraksi ciri tekstur yang digunakan, diantaranya adalah:

$$\text{kontras} = \sum |i-j|^2 p(i,j) \quad (8)$$

Kontras (*Contrast*) dalam GLCM adalah statistik yang mengukur perbedaan intensitas antara pasangan piksel dengan nilai tertinggi (terang) dan terendah (gelap).

$$\text{korelasi} = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i \sigma_j} \quad (9)$$

Korelasi (*Correlation*) dalam GLCM adalah metrik yang mengukur seberapa dekat atau berkorelasi pasangan piksel dalam matriks GLCM.

$$\text{energi} = \sum_{i,j} p(i,j)^2 \quad (10)$$

Energi (*Energy*) dalam GLCM adalah intensitas kekuatan total atau energi dari pasangan piksel yang muncul dalam matriks GLCM dengan tingkat keabuan tertentu.

$$\text{homogenitas} = \sum_{i,j} \frac{p(i,j)}{1 + |i-j|} \quad (11)$$

Homogenitas (*Homogeneity*) dalam GLCM adalah statistik yang mengukur tingkat keseragaman atau homogenitas variasi intensitas keabuan pada matriks tersebut.

$$\text{Disimilitas} = \sum_i \sum_j |i-j| \cdot p(i,j) \quad (12)$$

Disimilitas mengukur sejauh mana perbedaan suatu tekstur, dengan nilai yang lebih tinggi menunjukkan tingkat keacakannya yang lebih besar, dan nilai yang lebih rendah menunjukkan tingkat keseragamannya [14].

G. Metode K-Nearest Neighbor

Algoritma KNN mengklasifikasikan data menggunakan data pelatihan dari k tetangga terdekatnya [8]. Tahap klasifikasi ini menggunakan metode KNN untuk menemukan gambar ikan kembung yang baru dan lama. Pada tahap ini, proses pelatihan digunakan untuk membuat model KNN akurat, dan fitur uji digunakan untuk memprediksi hasil klasifikasi. Seperti yang ditunjukkan oleh rumus berikut:

d = jarak *data testing* ke data pelatihan.

y_j = data pelatihan ke j dengan $j = 1, 2, 3, 4 \dots n$.

x_j = *data testing* ke j , dengan $j = 1, 2, 3, 4 \dots n$

$$d(x-y) = \sum_{j=1}^i \sqrt{(x_j - y_j)} \quad (13)$$

H. Rancangan Pengujian

1) *Pengujian Metode KNN*: Pada pengujian ini, akan digunakan sampel citra latih dan kelas yang berbeda untuk menghitung jarak euclidean berdasarkan rumus (13) dengan menggunakan ikan kembung. Tujuan dari perhitungan ini adalah untuk menentukan kelas yang tepat pada citra uji.

2) *Pengujian Confusion Matrix*: Pada penelitian ini digunakan Confusion Matrix untuk mengukur performa pengujian. Dan dilakukan juga perhitungan terhadap *accuracy*, *recall* dan *precision* agar performa pengujian dapat diukur dengan maksimal. Penghitungan akurasi dilakukan dengan membandingkan hasil prediksi dengan data asli. Presisi dihitung untuk kemampuan model dalam mengidentifikasi kelas target secara tepat, sedangkan *recall* diukur untuk mengevaluasi seberapa baik model mengenali seluruh kelas target yang ada [15]. Rumus perhitungan akurasi, presisi dan *recall* dapat dilihat sebagai berikut:

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

$$\text{Presisi} = \frac{TP}{TP + FP} \quad (15)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (16)$$

III. HASIL DAN PEMBAHASAN

A. Implementasi Metode





Penelitian ini menggunakan metode yang terdiri dari lima tahap utama. Tahap-tahap tersebut meliputi pengumpulan data, pra-pemrosesan, segmentasi (*Thresholding*), ekstraksi ciri, dan pelatihan model.

B. Pengujian

Pengujian merupakan komponen penting dari pengembangan sistem yang bertujuan untuk mengevaluasi, menganalisis, dan menilai sejauh mana sistem yang telah

dirancang mencapai tingkat akurasi dan kesesuaian yang diinginkan. Dalam penelitian ini, dilakukan pengujian untuk mengevaluasi akurasi, presisi, dan *recall* dari implementasi metode *K-Nearest Neighbor* (KNN) dalam memprediksi atau mendeteksi label pada data uji, juga dilakukan pengujian untuk mengevaluasi tingkat presisi dan *recall* dari setiap label secara individu. Hasil data uji ditampilkan pada Tabel 1.

TABEL 1.
HASIL DATA UJI

No	Citra Uji	Label Aktual	Label Prediksi
1.		Ikan Kembang Segar	Ikan Kembang Segar
3.		Ikan Kembang Busuk	Ikan Kembang Busuk
4.		Ikan Kembang Segar	Ikan Kembang Segar
...
100.		Ikan Kembang Busuk	Ikan Kembang Busuk

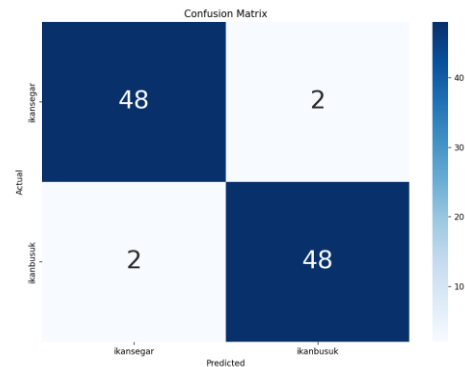
C. Pengujian Perfoma Model

Evaluasi model KNN dilakukan untuk memahami seberapa baik model tersebut dapat memprediksi label pada data yang belum pernah dilihat sebelumnya dengan melakukan pembagian *dataset* pelatihan yang telah dikonversi menjadi array dibagi menjadi dua bagian dengan rasio 70% atau 420 gambar ikan kembang untuk data latih (*data training*) dan 30% atau 180 gambar ikan kembang untuk data uji (*data testing*). Untuk setiap *k* nilai, hasil penelitian menunjukkan hasil paling akurat yang berbeda, meskipun beberapa nilai memiliki nilai yang sama. Hasil penelitian untuk *k* nilai yang digunakan dalam penelitian ditunjukkan dalam perhitungan Tabel 2 sebagai berikut:

TABEL 2.
PENGUJIAN PERFOMA MODEL

Pengujian Perfoma Model			
K-1	=	$(89 + 89 / 89 + 1 + 89 + 1) * 100$	= 98,88 %
	=	$(178 / 180) * 100$	
K-3	=	$(89 + 90 / 89 + 1 + 90) * 100$	= 99,44 %
	=	$(179 / 180) * 100$	
K-5	=	$(89 + 86 / 89 + 1 + 86 + 4) * 100$	= 97,22 %
	=	$(175 / 180) * 100$	
K-7	=	$(90 + 86 / 90 + 86 + 4) * 100$	= 97,77 %
	=	$(176 / 180) * 100$	
K-9	=	$(90 + 85 / 90 + 85 + 5) * 100$	= 97,22 %
	=	$(175 / 180) * 100$	

Hasil pengujian akurasi pada Tabel 2 menunjukkan bahwa model pengujian dengan pembagian *dataset training* 70:30. Di mana total 600 *dataset* dibagi menjadi 70%, atau 420 data, dan 30%, atau 180 data, untuk data uji. Dan tingkat akurasi tertinggi mencapai 99,44% didapat dari model KNN dengan *K*=3. Kemudian dilakukan uji coba dengan 100 data uji dengan menggunakan model terbaik, yaitu *K*=3. Gambar 8 menunjukkan hasil perhitungan *Confusion Matrix* dari model terbaik yang ditemukan.



Gambar 7. Hasil Perhitungan Confusion Matrix

Dari hasil confusion matrix pada Gambar 7 didapatkan informasi data aktual dan data prediksi. Nilai untuk kelas ikan segar dan ikan busuk dihasilkan dalam pengujian *dataset* untuk model yang telah dilakukan, Kotak yang berwarna menunjukkan nilai data aktual yang diprediksi benar atau *True Positive* (TP). Misalnya, diprediksi benar sebagai ikan kembang segar 48. data bukan ikan segar diprediksi benar sebagai bukan ikan kembang segar 48 atau *True Negative* (TN). Data yang sebenarnya ikan segar diprediksi bukan sebagai ikan segar berjumlah 2 atau *False Negative* (FN). Dan Data yang sebenarnya bukan ikan segar diprediksi sebagai ikan segar berjumlah 2 atau *False Positive* (FP). Berikut adalah perhitungan *Accuracy*, *Recall* dan *Precision* pada model yang didapat:

1) Perhitungan Accuracy:

$$Accuracy = \frac{48 + 48}{48 + 48 + 2 + 2} = 0.96 = 96\%$$

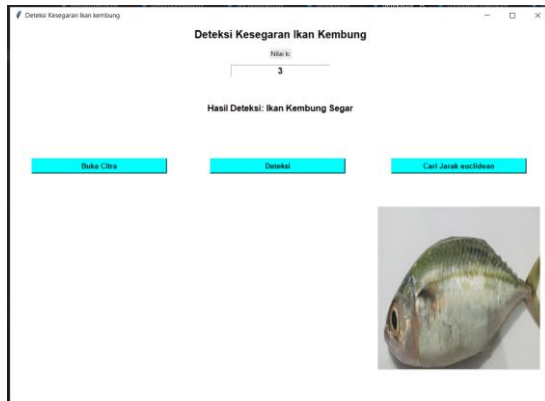
2) Perhitungan Recall:

$$Recall = \frac{48}{48 + 2} = 0.96 = 96\%$$

3) Perhitungan Precision:

$$Precision = \frac{48}{48 + 2} = 0.96 = 96\%$$

Berdasarkan Gambar 8 dan analisis *Confusion Matrix*, metode KNN berhasil dalam mengidentifikasi kesegaran ikan kembang. Tingkat akurasi yang dicapai sangat tinggi, hampir sempurna, menunjukkan bahwa metode ini efektif dan memberikan hasil yang memuaskan. Gambar 8 menampilkan hasil deteksi kesegaran ikan kembang.



Gambar 8. Visualisasi Hasil Prediksi

D. Pengujian Perhitungan KNN

Tabel 2 merupakan sampel citra latih dan kelas yang berbeda untuk menghitung *Euclidean Distance* berdasarkan rumus (13) dengan ekstraksi ciri untuk menentukan kelas pada Tabel 4 citra uji.

TABEL 3.
DATA LATIH

Citra Latih	Ekstraksi Ciri Wana Dan Tekstur	Kelas
50.jpg	[20.96558764940239 66.08351593625498 ... 0.031281091685881 0.031502926609855]	Ikan Busuk
150.jpg	[22.84553872053872 66.77327193503665 ... 0.030281072569737 0.027334258053135]	Ikan Busuk
250.jpg	[27.39471548188654 71.59948877876509 ... 0.024237173852639 0.02410699110272]	Ikan Busuk
350.jpg	[37.02852049910874 43.21106789823367 ... 0.023801889394677 0.023815949085265]	Ikan Segar
450.jpg	[36.35126128085246 42.4224475372404 ... 0.023434264022622 0.023425082450693]	Ikan Segar
550.jpg	[27.57095497904321 34.33498337910103 ... 0.022850003912594 0.021328047510681]	Ikan Segar

TABEL 4.
DATA UJI

Citra Uji	Ekstraksi Ciri Warna Dan Tekstur	Kelas
1.jpg	[36.572103043637696 31.155408874220754 ... 0.024362392929652307 0.022467368856783222]	?

TABEL 5.
PERHITUNGAN *EUCLIDEAN DISTANCE*

Citra Uji & Latih	Rumus <i>Euclidean Distance</i>	Hasil
1.jpg & 50.jpg	$\sqrt{(36.572103043637696 - 20.96558764940239)^2 + (31.155408874220754 - 66.08351593625498)^2 \dots}$	7.8553872813 1947
1.jpg & 150.jpg	$\sqrt{(36.572103043637696 - 22.84553872053872)^2 + (31.155408874220754 - 79.78362603012219)^2 \dots}$	4.8832879727 8702
1.jpg & 250.jpg	$\sqrt{(36.572103043637696 - 27.39471548188654)^2 + (31.155408874220754 - 71.59948877876509)^2 \dots}$	3.8733183992 0683
1.jpg & 350.jpg	$\sqrt{(36.572103043637696 - 37.02852049910874)^2 + (31.155408874220754 - 43.21106789823367)^2 \dots}$	3.3029935408 3015
1.jpg & 450.jpg	$\sqrt{(36.572103043637696 - 36.35126128085246)^2 + (31.155408874220754 - 42.4224475372404)^2 \dots}$	3.2702661093 1136

1.jpg & 550.jpg	$\sqrt{(36.572103043637696 - 27.57095497904321)^2 + (31.155408874220754 - 34.33498337910103)^2 \dots}$	3.5168434187 1916
-----------------	--------------------------------------------------------------------------------------------------------	----------------------

Pada pengujian yang ditunjukkan pada Tabel 5 dapat disimpulkan: Citra uji 1.jpg termasuk dalam kelas ikan segar karena memiliki jarak terkecil dengan Citra latih 350.jpg, 450.jpg dan 550.jpg yaitu: 3.30299354083015, 3.27026610931136 dan 3.51684341871916.

IV. KESIMPULAN

Hasil dari analisis, implementasi, dan pengujian sistem deteksi kesegaran ikan kembung ini telah berhasil dilaksanakan. Penelitian ini telah merancang dan menggunakan fitur tekstur GLCM dan warna RGB-HSV dalam pembuatan sistem deteksi kesegaran ikan kembung. Penelitian ini juga telah mengimplementasi metode *K-Nearest Neighbor* (KNN) dalam mendeteksi ikan segar dan ikan busuk. Pengujian sistem menggunakan normalisasi menunjukkan bahwa sistem deteksi kesegaran ikan kembung ini memiliki akurasi terbaik sebesar 96%. Dengan presisi sebesar 96% dan *recall* sebesar 96%. Ini menunjukkan bahwa model berfungsi dengan baik dalam mengenali dan mendeteksi kesegaran ikan kembung dengan tingkat keakuratan yang tinggi. Dengan demikian, sistem deteksi kesegaran ikan kembung menggunakan metode KNN mampu memberikan hasil yang handal dan dapat diandalkan dalam memprediksi kesegaran ikan kembung. Penelitian selanjutnya diharapkan penambahan kelas pendeteksian kesegaran ikan kembung supaya tidak hanya membedakan segar dan busuk saja, tetapi juga bisa mendeteksi sudah berapa lama waktu ikan kembung tersebut disimpan.

REFERENSI

- [1] C. Y. Jerandu, P. Batarius, dan A. A. J. Sinlae, "Identifikasi Kualitas Kesegaran Ikan Menggunakan Algoritma K-Nearest Neighbor Berdasarkan Ekstraksi Ciri Warna Hue, Saturation, dan Value (HSV)," *Building of Informatics, Technology and Science*, vol. 4, no. 3, hal. 1536–1547, 2022.
- [2] M. W. Adisaputra, "Kandungan Mikroplastik pada Ikan Bawis (*Siganus Canaliculatus*) dan ikan kembung (*Rastrelliger Kanagurta*) di perairan Bontang," *Jurnal Ilmiah BioSmart*, vol. 7, no. 1, hal. 1–11, 2021.
- [3] S. P. Hutagalung and G. Sitanggang, *Analisis Indikator Kinerja Utama Kelautan dan Perikanan Indonesia: Angka Konsumsi Ikan*, Jakarta, Pusat Data, Statistik, dan Informasi, 2017.
- [4] M. Alamsyah dan M. A. Nadjib, "Implementasi Metode K-Nearest Neighbor dalam Mengklasifikasikan Kesegaran Ikan Kuro Menggunakan Citra," *Jurnal SPIRIT*, vol. 14, no. 2, hal. 10–15, 2023.
- [5] E. H. Pujarini, F.N. Lenti, "Convolution Neural Network Untuk Identifikasi Tingkat Kesegaran Ikan Nila Berdasarkan Perubahan Warna Mata," *Jurnal Khatulistiwa Informatika*, vol. 11, no. 1, hal. 21–25, 2023.
- [6] H. Fitriyah, D. Syauqy, dan F. A. Susilo, "Deteksi Kesegaran Ikan Tongkol (*Euthynnus Affinis*) secara Otomatis Berdasarkan Citra Mata Menggunakan Binary Similarity," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 7, no. 5, hal. 879–886, 2020.
- [7] M. Sarimin, M. Bettiza, N. Hayaty, dan S. Nugraha, "Implementasi HSV dan GLCM untuk Deteksi Kesegaran Ikan Bawal menggunakan Radial Basis Function Berbasis Android," *Jurnal Sustainable: Jurnal Hasil Penelitian dan Industri Terapan*, vol. 8, no. 1, hal. 1–7, 2019.
- [8] Z. Y. Lamasigi, S. Serwin, H. Husdi, dan Y. Lasena, "Identifikasi Tingkat Kesegaran Ikan Tuna Menggunakan Metode GLCM dan KNN," *JAMBURA: Jurnal Electrical and Electronics Engineering*, vol. 4, no. 1, hal. 70–76, 2022.
- [9] S. Khansa, J. Jayanta, dan I. N. Isnainiyah, "Penerapan Ekstraksi Ciri Transformasi Wavelet Dalam Pembuatan Model Klasifikasi Kesegaran Ikan Selar," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, vol. 1, no. 2, hal. 771–784, 2020.

- [10] H. Honainah, F. F. Romadhoni, dan A. Ato'illah, "Klasifikasi Kesegaran Ikan Tongkol Berdasarkan Warna Mata Menggunakan Metode Backpropagation," *Jurnal Penelitian Inovatif*, vol. 2, no. 2, hal. 405–414, 2022.
- [11] E. P. H. Gutierrez, R. K. Hapsari, "Implementasi Metode Filter Gabor Pada Ekstraksi Fitur Image Wajah," *Seminar Nasional Teknik Elektro, Sistem Informasi, dan Teknik Informatika (SNESTIK)*, hal. 325–330, 2024.
- [12] I. W. A. Heryanto, M. Artama, M. W. Segara, I. G. A. Gunadi, "Segmentasi Warna dengan Metode Thresholding," *Wahana Matematika dan Sains: Jurnal Matematika, Sains, dan Pembelajarannya*, vol. 14, no. 1, hal. 54–64, 2020.
- [13] E. F. Himmah, M. Widyarningsih, dan M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *Jurnal Sains dan Informatika*, vol. 6, no. 2, hal. 193–202, 2020.
- [14] M. Ramadhani, S. Suprayogi, H. B. Dyah, "Klasifikasi Jenis Jerawat Berdasarkan Tekstur dengan Menggunakan Metode GLCM," *e-Prociding of Engineering*, vol. 5, no. 1, hal. 870–876, 2018.
- [15] G. M. C. Batubara, A. Desiani, dan A. Amran, "Klasifikasi Jamur Beracun Menggunakan Algoritma Naïve Bayes dan K-Nearest Neighbors," *Jurnal Ilmu Komputer dan Informatika*, vol. 3, no. 1, hal. 33–42, 2023.