

PENILAIAN KESEGERAN IKAN DENGAN METODE K-NEAREST NEIGHBOR DAN PENGOLAHAN CITRA DIGITAL

Vina Feriska Amalia, Reni Rahma Dewi

Teknik Elektro, Universitas Singaperbangsa Karawang
Telukjambe Timur, Puseurjaya, Karawang 4136, Indonesia
2010631160095@student.unsika.ac.id

ABSTRAK

Penelitian ini bertujuan untuk menentukan kesegaran ikan menggunakan metode K-Nearest Neighbor (K-NN) dan pengolahan citra digital. Penelitian ini penting karena kualitas ikan segar menjadi tolak ukur utama bagi konsumen, mengingat kandungan nutrisi seperti protein, omega-3, kalsium, vitamin D, dan fosfor yang tinggi. Sayangnya, tidak semua orang dapat membedakan ikan segar dari yang tidak layak konsumsi, yang berpotensi menyebabkan keracunan. Teknologi pengolahan citra diusulkan sebagai solusi untuk mengklasifikasikan kesegaran ikan berdasarkan parameter warna mata dan tubuh ikan. Metode yang digunakan melibatkan pengumpulan data citra RGB, preprocessing dengan konversi ke grayscale, ekstraksi fitur menggunakan metode HSV dan GLCM, serta klasifikasi menggunakan KNN dengan nilai k variabel. Hasil penelitian menunjukkan bahwa metode ini efektif dan efisien dalam menentukan kesegaran ikan, dengan akurasi yang signifikan. Metode GLCM digunakan untuk ekstraksi fitur dengan sudut 0° , 45° , 90° , dan 135° , serta jarak ketetanggaan $d=\{1 \text{ dan } 2\}$. Model K-NN dibor dengan nilai $k=\{3, 5, 7, \text{ dan } 9\}$, menunjukkan hasil akurasi yang bervariasi berdasarkan jarak ketetanggaan (d) dan nilai k yang digunakan dalam klasifikasi K-NN. Korelasi dengan $d=1$ dan $k=3$: rata-rata 95,16%. Korelasi dengan $d=1$ dan $k=5$: rata-rata 94,91, Korelasi dengan $d=1$ dan $k=7$: rata-rata 96,7. Korelasi dengan $d=1$ dan $k=9$: rata-rata 97,38. Hasil pengujian akurasi menunjukkan bahwa kombinasi parameter jarak tetangga $d=1$ dan $d=2$ dengan nilai $k=7$ dan $k=9$ memberikan kinerja terbaik.

Kata kunci: Citra digital, KNN, Kesegaran, Matlab, Klasifikasi, Ikan

1. PENDAHULUAN

Kualitas ikan segar adalah faktor utama yang mempengaruhi nilai gizi dan keamanan konsumsi ikan. Ikan segar mengandung nutrisi yang tinggi seperti protein, omega-3, kalsium, vitamin D, dan fosfor yang sangat penting untuk kesehatan manusia. Namun, menentukan kesegaran ikan tidak selalu mudah bagi konsumen awam, yang sering kali tidak dapat membedakan ikan segar dari yang tidak layak konsumsi. Hal ini dapat berpotensi menyebabkan masalah kesehatan seperti keracunan makanan. Seiring dengan kemajuan teknologi, pengolahan citra digital menawarkan solusi inovatif untuk mengklasifikasikan kesegaran ikan secara lebih objektif dan akurat dibandingkan penilaian manual. Pengolahan citra memungkinkan analisis visual yang lebih mendalam dan dapat mengurangi subjektivitas dalam penilaian kesegaran ikan. Dalam penelitian ini, metode K-Nearest Neighbor (K-NN) digunakan sebagai algoritma utama untuk klasifikasi kesegaran ikan berdasarkan parameter visual seperti warna mata dan tubuh ikan.[1]

Metode K-Nearest Neighbor (K-NN) adalah algoritma pembelajaran mesin yang bersifat non-parametrik dan lazy learning. Algoritma ini tidak membuat asumsi tentang distribusi data yang mendasarinya dan tidak menggunakan data training untuk membentuk model. Sebaliknya, semua data training digunakan pada tahap pengujian. Prinsip dasar K-NN adalah mencari sejumlah k tetangga terdekat dalam ruang fitur dan menentukan kelas dari sampel berdasarkan mayoritas kelas dari tetangga-tetangga

tersebut. Keunggulan utama dari K-NN adalah kesederhanaannya dan kemampuannya untuk menangani data non-linear. Langkah-langkah yang dilakukan dalam penelitian ini meliputi pengumpulan data citra ikan, preprocessing citra, ekstraksi fitur, pelatihan model K-NN, dan pengujian model. Data citra ikan dikumpulkan dari sampel ikan yang disimpan pada suhu ruang selama 15 jam. Setiap citra dikategorikan ke dalam lima kelas kesegaran berdasarkan waktu penyimpanan dan kondisi fisik.

Proses preprocessing melibatkan konversi citra RGB ke grayscale untuk memudahkan ekstraksi fitur dan normalisasi citra untuk mengurangi noise. Ekstraksi fitur dilakukan menggunakan metode HSV (Hue, Saturation, Value) dan GLCM (Gray-Level Co-occurrence Matrix). Metode HSV digunakan untuk menangkap informasi warna, sementara GLCM digunakan untuk mengukur tekstur citra. Data yang telah di preprocessing dan diekstraksi fiturnya kemudian digunakan untuk melatih model KNN. Nilai k dalam KNN ditentukan melalui eksperimen untuk menemukan k yang optimal. Penggunaan parameter warna dan tekstur dalam analisis citra terbukti efektif dalam membedakan ikan segar dari yang tidak segar.[2]

Penelitian ini menunjukkan bahwa metode K-NN dapat memberikan klasifikasi yang akurat terhadap kesegaran ikan. Akurasi, presisi, dan recall digunakan sebagai matrik evaluasi. Penggunaan teknologi pengolahan citra digital dan K-NN dalam menentukan kesegaran ikan tidak hanya memberikan hasil yang lebih akurat tetapi juga efisien dan dapat diterapkan

dalam skala industri. Implementasi metode ini dapat membantu memastikan kualitas ikan yang dipasarkan kepada konsumen, sehingga meningkatkan kepercayaan dan keselamatan konsumen.

2. TINJAUAN PUSTAKA

Beberapa studi sebelumnya telah dilakukan oleh para peneliti, yang telah menghasilkan temuan-temuan yang dapat dibandingkan dengan penelitian yang akan dilakukan oleh penulis. Di bawah ini, akan dijelaskan secara ringkas beberapa referensi tersebut:

Penelitian yang berjudul “Implementasi Metode KNN Dalam Mengklasifikasikan Kesegaran Ikan Kuro Menggunakan Citra” oleh Muslim Alamsyah, Muhammad Ainun Nadjib dari Universitas Merdeka, Pasuruan, Indonesia, 2022. Pada Penelitian ini membahas pentingnya mengetahui kesegaran ikan kuro (*Eleutheronema Tetradactylum*) untuk memastikan kandungan nutrisi yang optimal. Metode tradisional untuk memeriksa kesegaran ikan dianggap kurang efektif, sehingga penelitian ini menggunakan metode K-Nearest Neighbor (KNN) untuk klasifikasi berdasarkan citra warna mata dan tubuh ikan. Dengan menggunakan 40 data latih dan 16 data uji, hasil penelitian menunjukkan akurasi 100% pada data latih namun hanya 43,75% pada data uji. Kesimpulannya, metode KNN efektif pada data latih namun memerlukan perbaikan untuk meningkatkan akurasi pada data uji.[3]

Penelitian yang berjudul “Identifikasi Tingkat Kesegaran Ikan Tuna Melalui Citra Mata Menggunakan Metode K-Nearest Neighbor (KNN)” Oleh Santosa, Sakinah Sudin, Nining S. Kamala dari Universitas Muhammadiyah Maluku Utara, 2022. Pada penelitian ini mendeteksi tingkat kesegaran ikan tuna (*Thunnus*) secara otomatis menggunakan metode K-Nearest Neighbor (KNN) melalui analisis citra mata ikan. Latar belakang penelitian ini adalah kebutuhan untuk mengembangkan sistem otomatis yang dapat menggantikan metode manual yang sering tidak akurat karena keterbatasan indra penglihatan manusia. Metode yang digunakan dalam penelitian ini melibatkan pengambilan citra mata ikan tuna, ekstraksi fitur warna RGB yang kemudian dikonversi ke ruang warna Lab, serta penerapan algoritma KNN untuk klasifikasi. Hasil penelitian menunjukkan bahwa metode KNN mampu melakukan klasifikasi dengan tingkat akurasi sebesar 60% untuk mengukur kesegaran ikan selama tiga hari. Kesimpulannya, metode KNN cukup efektif, namun akurasinya masih perlu ditingkatkan dengan metode lain untuk mendeteksi kesegaran ikan tuna secara lebih akurat.[4]

Penelitian yang berjudul “Perbandingan Algoritma KNN, C4.5, dan Naive Bayes dalam Pengklasifikasian Kesegaran Ikan Menggunakan Media Foto” Wella, Ni Made Satvika Iswari, Ranny dari Universitas Multimedia Nusantara, 2017. Pada penelitian ini mengembangkan metode klasifikasi kesegaran ikan berdasarkan citra digital dengan menggunakan algoritma kNN, C4.5, dan Naive Bayes.

Prosesnya melibatkan pengambilan foto mata ikan, peringkasan warna menggunakan nilai RGB, dan pengklasifikasian menggunakan ketiga algoritma tersebut. Hasilnya menunjukkan bahwa algoritma kNN memberikan akurasi tertinggi, menjadikannya pilihan terbaik untuk klasifikasi kesegaran ikan. Metode ini diharapkan dapat mengotomatisasi dan meningkatkan efisiensi proses produksi ikan yang sebelumnya dilakukan secara manual.[5]

Penelitian yang berjudul “Penggunaan K-Nearest Neighbor (KNN) untuk Mengklasifikasi Citra Belimbing Berdasarkan Fitur Warna” oleh Duwen Imantata Muhammad, Ermatita, Noor Falih dari Universitas Pembangunan Nasional Veteran Jakarta, 2021. Pada penelitian ini dilatarbelakangi oleh kebutuhan untuk mengklasifikasi tingkat kematangan buah belimbing secara lebih akurat dibandingkan dengan metode pengamatan manual yang seringkali tidak akurat dan subyektif. Buah belimbing, khususnya di kota Depok yang dikenal sebagai kota belimbing, dipilih sebagai objek penelitian karena popularitasnya. Penelitian ini bertujuan untuk mengidentifikasi tingkat kematangan buah belimbing berdasarkan citra digital menggunakan algoritma K-Nearest Neighbor (KNN) dan metode ekstraksi fitur Hue Saturation Value (HSV). Data citra buah belimbing Dewi dengan tingkat kematangan berbeda dikumpulkan, dan citra diambil dari sudut yang berbeda. Pra proses meliputi resize citra menjadi ukuran 500x500 pixel dan segmentasi background. Ekstraksi ciri menggunakan metode HSV untuk mendapatkan nilai hue, saturation, dan value dari citra. Data yang telah diekstraksi kemudian diklasifikasikan menggunakan algoritma KNN dengan beberapa tahapan seperti menetapkan nilai K, menghitung jarak Euclidean, dan menentukan hasil klasifikasi berdasarkan kelas dengan nilai K terbanyak. Evaluasi model menunjukkan akurasi klasifikasi sebesar 93.33% pada percobaan dengan nilai K=7.[6]

Pada penelitian yang berjudul “Identifikasi Pengenalan Wajah Dengan Menggunakan Metode K-Nearest Neighbor (KNN) dan LPBH (*Local Binary Pattern Histogram*) Untuk Sistem Presensi oleh Di Rizki Yulianti, Iwan Iwut Triastomoro, Sofia Sa'idah, Universitas Telkom, 2022. Pada penelitian ini dalam kegiatan belajar mengajar, dimana sistem presensi manual memiliki banyak kelemahan seperti peluang kecurangan dan kesalahan dalam rekap data. Untuk mengatasi masalah ini, penelitian ini mengembangkan sistem presensi otomatis menggunakan pengenalan wajah (*face recognition*) dengan metode K-Nearest Neighbor (KNN) dan Local Binary Pattern Histogram (LBPH). Data penelitian diambil dari citra wajah yang di-capture menggunakan webcam, dengan total 750 citra wajah dari 30 individu. Sistem ini melalui beberapa tahap seperti deteksi wajah, pembuatan dataset wajah, training, dan pengenalan wajah menggunakan library OpenCV berbasis Python. Hasil penelitian menunjukkan bahwa metode LBPH dalam pengenalan wajah mencapai akurasi rata-rata 93.9%,

dengan nilai False Acceptance Rate (FAR) 4.66% dan False Rejection Rate (FRR) 1.33%. Sedangkan untuk klasifikasi KNN, akurasi tertinggi sebesar 100% diperoleh pada nilai $k=1$ dengan waktu komputasi 34 ms.[7]

2.1. Akuisisi Citra

Akuisisi citra adalah proses pembentukan citra yang dilakukan sebelum tahap perbaikan citra. Akuisisi citra merupakan salah satu langkah penting dalam pengolahan citra. Akuisisi citra dapat dibagi menjadi tiga kategori berdasarkan jenis sensor yang digunakan: sensor tunggal, sensor strip, dan sensor array. Dalam sistem pemrosesan citra digital, terdapat empat komponen utama, yaitu:

- a. Digitizer
- b. Komputer Digital
- c. Perangkat tampilan
- d. Perangkat penyimpanan

Keempat komponen ini membagi sistem pemrosesan citra digital menjadi empat kategori: digitalisasi, pemrosesan, penayangan, dan penyimpanan. Digitizer (sistem akuisisi citra digital) adalah sistem yang mengonversi hasil penangkapan citra digital menjadi representasi numerik yang digunakan sebagai masukan bagi komputer digital. Hasil dari digitizer berupa matriks dengan elemen-elemen yang merepresentasikan nilai intensitas cahaya pada setiap titik. Contoh digitizer meliputi kamera digital dan pemindai. Digitizer terdiri dari tiga komponen: sensor citra yang mengukur intensitas cahaya, konverter analog ke digital yang melakukan sampling dan kuantisasi, serta perangkat pemindaian yang merekam hasil pengukuran intensitas pada seluruh bagian citra.[8]

2.2. Pengolahan Citra Digital

Pengolahan citra adalah proses manipulasi citra, khususnya menggunakan komputer, untuk meningkatkan kualitas citra tersebut. Tujuan dari pengolahan citra adalah memperbaiki kualitas citra sehingga lebih mudah diinterpretasikan oleh manusia atau mesin (komputer). Teknik-teknik pengolahan citra mentransformasikan citra asli menjadi citra baru.[9]

Pengolahan citra merupakan salah satu cabang ilmu dalam kecerdasan buatan yang menggunakan citra digital untuk memecahkan masalah. Metode dalam pengolahan citra meliputi penggunaan perhitungan matematis baik pada level piksel maupun geometris dari objek citra. Setiap objek citra memiliki karakteristik yang unik yang dapat diukur secara matematis, seperti warna, tekstur, dan bentuk, yang memungkinkan untuk membedakan antara satu objek dengan objek lainnya.

2.3. Matlab

Matlab adalah sebuah bahasa pemrograman tingkat tinggi yang memiliki karakteristik dan fungsi unik yang membedakannya dari bahasa pemrograman

lain yang sudah ada seperti Delphi, Basic, dan C++. Matlab dirancang khusus untuk memenuhi kebutuhan dalam komputasi teknis, visualisasi, serta pemrograman seperti komputasi matematika, analisis data, pengembangan algoritma, simulasi, dan pemodelan grafis. Matlab dikenal karena menyediakan berbagai fungsi matematis, fisika, statistik, dan visualisasi, yang memudahkan pengguna dalam menyelesaikan berbagai masalah, baik yang sederhana maupun kompleks dari berbagai disiplin ilmu. Awalnya dikembangkan oleh MathWorks untuk mempermudah akses terhadap data matriks dalam proyek LINPACK dan EISPACK, Matlab saat ini telah berkembang menjadi alat yang sangat bervariasi dan kuat dengan ratusan fungsi yang tersedia untuk menyelesaikan masalah-masalah teknis.[10]


GUIDE atau GUI Builder adalah sebuah Graphical User Interface (GUI) yang memanfaatkan objek-objek grafis seperti tombol (button), kotak teks, slider, menu, dan lain-lain. Penggunaan GUI dalam aplikasi umumnya membuatnya lebih mudah dipelajari dan digunakan karena pengguna tidak perlu memiliki pengetahuan mendalam tentang perintah-perintah atau cara kerja aplikasi tersebut.

2.4. K-Nearest Neighbor (K-NN)

Algoritma K-Nearest Neighbor (KNN) adalah algoritma pembelajaran mesin yang bersifat non-parametrik dan lazy learning. Metode non-parametrik tidak membuat asumsi apa pun tentang distribusi data yang mendasarinya, artinya, model tidak memiliki jumlah parameter tetap, terlepas dari ukuran data. Algoritma non-parametrik seperti KNN menggunakan sejumlah parameter yang fleksibel, yang sering kali bertambah seiring dengan bertambahnya data. Meskipun komputasinya lebih lambat, metode ini membuat lebih sedikit asumsi tentang data. KNN juga bersifat lazy learning, yang berarti algoritma ini tidak menggunakan data training untuk membentuk model. Pada KNN, tidak ada fase pelatihan yang signifikan; semua data training digunakan pada tahap pengujian. Hal ini membuat proses pelatihan lebih cepat, sementara tahap pengujian menjadi lebih lambat dan memerlukan banyak waktu dan memori.[11]

3. METODE PENELITIAN

Metode penelitian kesegaran ikan dilakukan akuisisi citra pada 5 ikan yang disimpan di suhu ruang selama 15 jam. Citra ikan tersebut dikategorikan ke dalam lima kelas kesegaran ikan. Kelas pertama adalah ikan segar, sementara kelas kedua adalah ikan yang mulai membusuk setelah disimpan selama 5 jam. Kelas ketiga adalah ikan busuk yang disimpan selama 10 jam. Setiap ikan pada setiap kelas difoto sebanyak tiga kali, sehingga menghasilkan total 24 gambar pada setiap kelas kesegaran. Secara keseluruhan, terdapat gambar ikan berbasis RGB (red, green, blue). Gambar-gambar ini kemudian terbagi untuk proses pelatihan dan 15 gambar untuk proses pengujian.



Gambar 1. Metodologi Penelitian

3.1. Pengumpulan Data

Pengumpulan data merupakan langkah pertama yang sangat penting dalam penelitian ini. Proses ini dilakukan dengan cara melakukan akuisisi citra pada 10 ekor ikan yang disimpan pada suhu ruang selama 15 jam. Untuk mengkategorikan tingkat kesegaran ikan, ikan-ikan tersebut dibagi ke dalam lima kelas kesegaran, yang mencerminkan berbagai tahap pembusukan:

- Kelas 1
Ikan segar yang baru diambil dari tempat penyimpanan.
- Kelas 2
Ikan yang mulai menunjukkan tanda-tanda pembusukan setelah disimpan selama 5 jam.
- Kelas 3
Ikan yang sudah membusuk setelah disimpan selama 10 jam.

Setiap ikan dalam masing-masing kelas difoto sebanyak tiga kali, menghasilkan total 15 gambar per kelas kesegaran. Dengan demikian, total terdapat 45 gambar ikan berbasis RGB (red, green, blue). Gambar-gambar ini kemudian dibagi menjadi 30 gambar untuk proses pelatihan model dan 15 gambar untuk proses pengujian model.

3.2. Preprocessing

Pada tahap preprocessing, citra yang telah dikumpulkan diproses lebih lanjut untuk meningkatkan kualitas citra dan mempersiapkannya untuk tahap ekstraksi fitur. Langkah-langkah preprocessing meliputi:

- Konversi Citra ke Format Grayscale:
Citra dikonversi ke format grayscale untuk menyederhanakan analisis.
- Peningkatan Kontras Citra
Kontras citra ditingkatkan untuk memastikan perbedaan warna lebih jelas terlihat.
- Penghapusan Noise
Penghapusan noise dilakukan untuk membersihkan citra dari gangguan-gangguan yang dapat mempengaruhi analisis.

3.3. Ekstraksi Fitur/Citra Warna

Dalam penelitian ini, metode ekstraksi ciri warna yang digunakan adalah metode HSV (Hue, Saturation, Value). Langkah pertama dalam metode ini adalah konversi citra dari format RGB ke format HSV. Konversi ini dapat dilakukan menggunakan fungsi 'rgb2hsv' pada Matlab. Setelah konversi, tahap selanjutnya adalah pembuatan histogram HSV. Setiap komponen H (Hue), S (Saturation), dan V (Value)

dinyatakan dengan histogram yang menggambarkan distribusi nilai masing-masing komponen dalam citra. Dengan demikian, citra HSV dinyatakan dengan tiga buah histogram yang terdiri dari histogram H, S, dan V. Proses ini dilakukan pada citra RGB yang sudah dikonversi ke model HSV, sehingga menghasilkan tiga histogram yang mencerminkan distribusi warna, saturasi, dan kecerahan dalam citra tersebut.

3.4. Model KNN

Pada tahap ini, data pelatihan yang terdiri dari 45 gambar digunakan untuk melatih model KNN. Model ini akan mempelajari pola dan karakteristik dari fitur warna untuk masing-masing kelas kesegaran ikan. Proses pembentukan model KNN meliputi:

- Pemilihan Parameter K
Parameter K, yang menentukan jumlah tetangga terdekat yang akan digunakan dalam klasifikasi, dipilih berdasarkan eksperimen dan pengujian awal.
- Pelatihan Model
Data pelatihan digunakan untuk melatih model KNN dengan membandingkan nilai-nilai RGB dari citra dengan nilai-nilai dari tetangga terdekatnya.

3.5. Pengujian

Setelah model KNN terbentuk, model diuji menggunakan 5 gambar yang tidak digunakan dalam proses pelatihan. Data uji ini berfungsi untuk mengevaluasi kinerja model KNN dalam kondisi yang lebih nyata. Tahap pengujian meliputi:

- Klasifikasi Data Uji
Setiap citra dalam data uji diklasifikasikan menggunakan model KNN.
- Evaluasi Kinerja
Hasil klasifikasi dibandingkan dengan label sebenarnya untuk menghitung akurasi dan performa model.

3.6. Hasil Uji dan Akurasi

Hasil pengujian dianalisis untuk menentukan seberapa baik model KNN dalam mengklasifikasikan tingkat kesegaran ikan. Akurasi dihitung dengan membandingkan hasil klasifikasi model dengan label sebenarnya dari data uji.

4. HASIL DAN PEMBAHASAN

4.1. Dataset

Dataset merupakan foto ikan yang diambil dari percobaan terdahulu [8]. Data set berisi 25 data latih dan 150 data uji.






Tabel 1. Jumlah Data Uji dan Data Latih

No	Perbandingan Waktu	Data Uji	Data Latih
1	2 Jam	5	30
2	5 Jam	5	30
3	10 Jam	5	30
4	15 Jam	5	30
5	20 Jam	5	30
Jumlah		25	150
		175	


4.2. Preprocessing dan Segmentasi





Penelitian ini memanfaatkan dataset citra dalam format RGB, tetapi untuk analisis, citra tersebut harus dikonversi ke format grayscale. Oleh karena itu, tahap preprocessing melibatkan konversi dari RGB ke grayscale. Proses ini diterapkan secara terpisah pada data latih dan data uji untuk memastikan konsistensi dan keakuratan hasil analisis. Dengan segmentasi, bagian-bagian yang tidak relevan atau latar belakang dapat diabaikan, sehingga meningkatkan akurasi ekstraksi fitur.

Tabel 2. Hasil Preprocessing dan Segmentasi Data Uji

No	Waktu	Data Uji
1	2 Jam	
2	5 Jam	
3	10 Jam	
4	15 Jam	
5	20 Jam	

Tabel 3. Hasil Preprocessing dan Segmentasi Data Latih

No	Waktu	Data Latih
1	2 Jam	

2	5 Jam	
3	10 Jam	
4	15 Jam	
5	20 jam	

4.3. Ekstraksi Fitur GLCM

Tabel 4. Hasil Ekstraksi Fitur GLCM Data Uji

No	Waktu	Data Uji			
1	2 Jam	Contrast	Correlation	Energy	Homogeneity
		499.14	0.9605	0.00066592	0.26576
		643.73	0.94897	0.00063109	0.2458
		438.69	0.96521	0.00078203	0.27921
		842.38	0.93322	0.00059623	0.23785
2	5 Jam	Contrast	Correlation	Energy	Homogeneity
		558.6	0.95473	0.00054271	0.25404
		717.54	0.94188	0.0005138	0.23754
		470.29	0.96187	0.00062411	0.27004
		871.86	0.92937	0.00048528	0.23138
3	10 Jam	Contrast	Correlation	Energy	Homogeneity
		499.14	0.9605	0.00066592	0.26576
		643.73	0.94897	0.00063109	0.2458
		438.69	0.96521	0.00078203	0.27921
		842.38	0.93322	0.00059623	0.23785
4	15 Jam	Contrast	Correlation	Energy	Homogeneity
		59.935	0.9882	0.00089707	0.40134
		110.46	0.97789	0.00074409	0.34634
		66.905	0.9866	0.00096515	0.39785
		95.027	0.98058	0.00077575	0.35364
5	20 Jam	Contrast	Correlation	Energy	Homogeneity
		155.1	0.97366	0.0004225	0.30725
		206.61	0.96495	0.00034125	0.27203
		144.18	0.97547	0.00040257	0.30214
		252.73	0.95713	0.00033407	0.26615

Tabel 5. Hasil Ekstraksi Fitur GLCM Data Latih

No	Waktu	Data Uji			
1	2 Jam	Contrast	Correlation	Energy	Homogeneity
		293.28	0.96828	0.00049199	0.30439
		426.16	0.95235	0.00039945	0.27392
		300.4	0.96634	0.00048469	0.30759
		413.24	0.95379	0.00049059	0.26992
2	5 Jam	Contrast	Correlation	Energy	Homogeneity
		114.23	0.98426	0.0011306	0.38229
		168.32	0.97685	0.00088957	0.33502
		101.24	0.98607	0.0011629	0.35588
		192.91	0.97353	0.00095524	0.33974
3	10 Jam	Contrast	Correlation	Energy	Homogeneity
		143.39	0.98039	0.0010351	0.38588
		278.52	0.96655	0.001467	0.33402
		184.65	0.98142	0.0018947	0.38677
		242.05	0.97093	0.0016258	0.33421
4	15 Jam	Contrast	Correlation	Energy	Homogeneity
		558.6	0.95473	0.00054271	0.25404
		717.54	0.94188	0.0005138	0.23754
		470.29	0.96187	0.00062411	0.27004
		871.86	0.92937	0.00048528	0.23138
5	20 jam	Contrast	Correlation	Energy	Homogeneity
		118.12	0.98383	0.0010372	0.3753
		145.52	0.97738	0.00083993	0.33868
		90.78	0.98759	0.0011287	0.3956
		189.22	0.97814	0.00089728	0.34141

4.4. Analisis Hasil

Selanjutnya, mengidentifikasi kualitas ikan menggunakan ekstraksi fitur GLCM dan dengan sudut 0° , 45° , 90° , dan 135° serta jarak ketetanggaan $d = \{1$

dan 2}. Selanjutnya, lakukan klasifikasi menggunakan metode K-NN dengan nilai $k = \{3, 5, 7, \text{ dan } 9\}$.

Tabel 6. Hasil Klasifikasi:

d 1 (3)	0	45	90	135	AVG
Corelation	0.96117	0.94318	0.95651	0.94545	0.95158
Energy	0.11215	0.10657	0.11208	0.10482	0.10891
Homogeneity	0.89039	0.87111	0.89032	0.86739	0.8798
d 1 (5)					
Corelation	0.95342	0.93635	0.95728	0.93946	0.94663
Energy	0.12307	0.11202	0.12121	0.11436	0.11767
Homogeneity	0.90427	0.87967	0.90252	0.88388	0.89259
d 1 (7)					
Correlation	0.97362	0.96089	0.9713	0.96483	0.96766
Energy	0.18313	0.17032	0.18	0.17526	0.17718
Homogeneity	0.93953	0.91641	0.9355	0.92522	0.92916
d 1 (9)					
Correlation	0.95317	0.93067	0.9565	0.93918	0.94488
Energy	0.10944	0.096419	0.10823	0.10034	0.10361
Homogeneity	0.87833	0.84009	0.87573	0.85308	0.86181
d2 (3)					
Correlation	0.9556	0.9395	0.9537	0.93984	0.94716
Energy	0.10394	0.099551	0.10516	0.09728	0.10148
Homogeneity	0.88411	0.86882	0.88769	0.86295	0.87589
d 2 (5)					
Correlation	0.96117	0.94318	0.95651	0.94545	0.95158
Energy	0.11215	0.10657	0.11208	0.10482	0.10891
Homogeneity	0.89039	0.87111	0.89032	0.86739	0.8798
d 2 (7)					
Correlation	0.95342	0.93635	0.95728	0.93946	0.94663
Energy	0.12307	0.11202	0.12121	0.11436	0.11767
Homogeneity	0.90427	0.87967	0.90252	0.88388	0.89259
d 2 (9)					
Correlation	0.97263	0.96722	0.97732	0.96338	0.97014
Energy	0.18294	0.17845	0.18636	0.17817	0.18148
Homogeneity	0.92773	0.91768	0.93593	0.91552	0.92422

- Korelasi tertinggi dicapai pada kombinasi $d1, k=7$ dan $d2, k=9$. Ini menunjukkan bahwa pada kombinasi tersebut, hubungan antara piksel tetangga dalam citra ikan lebih konsisten, yang membantu dalam klasifikasi kesegaran ikan.
- Energi tertinggi dicapai pada kombinasi $d1, k=7$ dan $d2, k=9$. Energi yang lebih tinggi menunjukkan tekstur citra yang lebih seragam, yang bisa menjadi indikator penting dalam menentukan kesegaran ikan.
- Homogenitas tertinggi dicapai pada kombinasi $d1, k=7$ dan $d2, k=9$. Homogenitas yang tinggi menunjukkan bahwa intensitas piksel dalam citra lebih seragam, yang juga membantu dalam mengidentifikasi kesegaran ikan.

Secara keseluruhan, kombinasi jarak tetangga $d=1$ dan $d=2$ dengan nilai $k=7$ dan $k=9$ memberikan hasil klasifikasi yang lebih konsisten dan akurat dalam menentukan

kesegaran ikan berdasarkan fitur GLCM. Kombinasi ini menunjukkan performa yang lebih baik dalam hal korelasi, energi, dan homogenitas.

5. KESIMPULAN

Penelitian ini menunjukkan bahwa metode K-Nearest Neighbor (KNN) dapat digunakan secara efektif untuk mengidentifikasi kesegaran ikan berdasarkan citra digital. Hasil penelitian menunjukkan bahwa penggunaan fitur warna RGB pada citra mata ikan mampu memberikan hasil klasifikasi yang akurat. Kombinasi parameter jarak tetangga $d=1$ dan $d=2$ dengan nilai $k=7$ dan $k=9$ memberikan performa terbaik dalam hal korelasi, energi, dan homogenitas. Dengan demikian, metode KNN dapat menjadi alat yang andal dalam proses identifikasi kesegaran ikan, yang sangat penting dalam industri perikanan untuk memastikan kualitas dan keamanan produk yang dijual.

DAFTAR PUSTAKA

- R. N. Situmorang, "Klasifikasi Kesegaran Ikan Berdasarkan Ekstraksi Fitur Menggunakan

- Metode K-Nearest Neighbor dan Hue Saturation Value," Skripsi, Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, Medan, 2021. [Online]. Available: <http://repository.uinsu.ac.id/15283/1/PERPUS%28RIZKINURSAFITRI%29.pdf>
- [2] D. Syahid, Jumadi, and D. Nursantika, "Sistem Klasifikasi Jenis Tanaman Hias Daun Philodendron Menggunakan Metode K-Nearest Neighbor (KNN) Berdasarkan Nilai Hue, Saturation, Value (HSV)," *J. Online Inform.*, vol. 1, pp. 20-23, 2016.
- [3] M. Alamsyah and M. A. Nadjib, "Implementasi Metode KNN Dalam Mengklasifikasikan Kesegaran Ikan Kuro Menggunakan Citra," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 9, no. 1, pp. 56-64, 2022.
- [4] S. Santosa, S. Sudin, and N. S. Kamala, "Identifikasi Tingkat Kesegaran Ikan Tuna Melalui Citra Mata Menggunakan Metode K-Nearest Neighbor (KNN)," *Jurnal PRODUKTIF*, vol. 6, no. 1, pp. 517-523, 2022.
- [5] Wella, N. M. S. Iswari, and Ranny, "Perbandingan Algoritma kNN, C4.5, dan Naive Bayes dalam Pengklasifikasian Kesegaran Ikan Menggunakan Media Foto," *ULTIMATICS*, vol. IX, no. 2, pp. 114-117, Dec. 2017.
- [6] D. I. Muhammad, Ermatita, and N. Falih, "Penggunaan K-Nearest Neighbor (KNN) untuk Mengklasifikasi Citra Belimbing Berdasarkan Fitur Warna," *Jurnal Informatik*, vol. 17, no. 1, pp. 9-17, Apr. 2021.
- [7] D. R. Yulianti, I. I. Triastomoro, and S. Sa'idah, "Identifikasi pengenalan wajah dengan menggunakan metode KNN (K-Nearest Neighbor) dan LBPH (Local Binary Pattern Histogram) untuk sistem presensi," *Jurnal TEKINKOM*, vol. 5, no. 1, pp. 1-10, Jun. 2022. doi: 10.37600/tekinkom.v5i1.477.
- [8] H. Zhou, J. Wu, and J. Zhang, *Pengolahan Citra Digital: Bagian I, Bagian 1*. Buku Buku, 2010.
- [9] M. Widyarningsih, "Identifikasi Kematangan Buah Apel Dengan Gray Level Co-Occurrence Matrix (GLCM)," *Jurnal SAINTEKOM*, vol. 6, no. 1, p. 71, 2017. Available: <https://doi.org/10.33020/saintekom.v6i1>.
- [10] MathWorks, "GUI MATLAB," [Online]. Available: <https://www.mathworks.com/discovery/matlab-gui.html>.
- [11] ADMINLP2M, "Algoritma K-Nearest Neighbors (KNN) – Pengertian dan Penerapan," [Online]. Available: https://www.academia.edu/9131959/A._Klasifikasi_K-Nearest_Neighbor.
- [12] F. Azzahra and E. Hartati, "Identifikasi Kadar Ikan Pada Pempek Menggunakan K-NN Dengan Fitur GLCM," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 4, pp. 281-290, Dec. 2023. Available: <http://jurnal.mdp.ac.id>.
- [13] A. Salsabila, R. Yunita, and C. Rozikin, "Identifikasi Citra Jenis Bunga Menggunakan Algoritma KNN Dengan Ekstraksi Warna HSV dan Tekstur GLCM," *Technomedia Journal*, vol. 6, no. 1, pp. 124-137, Jul. 2021. doi: 10.33050/tmj.v6i1.1667.
- [14] A. Prabowo, D. Erwanto, and P. N. Rahayu, "Klasifikasi Kesegaran Daging Sapi Menggunakan Metode Ekstraksi Tekstur GLCM dan KNN," *Electro Luceat*, vol. 7, no. 1, pp. 74-81, Jul. 2021.
- [15] D. Bee, W. Weku, and A. J. Rindengan, "Aplikasi Penentuan Tingkat Kesegaran Ikan Selar Berbasis Citra Digital Dengan Metode Kuadrat Terkecil," *CARTESIAN*, vol. 5, no. 2, p. 121, Oct. 2016. doi: 10.35799/dc.5.2.2016.14985.
- [16] R. A. F. Zahro, "dataset source code rizalfachrezi," [Online]. Available: <https://github.com/rizalfachrezi/TUGAS-EKSTRAKSI-FITUR-1918093-C--Rizal-Ahmad-Fahrezi-Zahro>.
- [17] P. Kumar and A. Kumar, "Fish Quality Analysis Using Computer Vision and Machine Learning: A Review," *Journal of Food Science and Technology*, vol. 56, no. 4, pp. 1431-1442, 2019.