

IDENTIFIKASI KUALITAS IKAN CAKALANG SEGAR BERBASIS CITRA MATA MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM) DENGAN FUNGSI KERNEL RADIAL BASIS FUNCTION

Sri Adiningsi, Bambang Pramono, Adha Mashur Sajiah, Rizal Adi Saputra

Teknik Informatika, Universitas Halu Oleo

Kampus Hijau Bumi Tridharma, Anduonohu, Kec. Kambu, Kota Kendari, Sulawesi, Indonesia

sriadiningsi21@gmail.com

ABSTRAK

Sulawesi Tenggara, yang mengalami peningkatan potensi perikanan dari 11,25% pada 2019 menjadi 11,60% pada 2021, memiliki kontribusi besar dalam komoditas seperti cakalang, dengan tangkapan sebesar 21.868 ton senilai Rp 501 miliar. Namun, tantangan utama yang dihadapi adalah jaminan mutu dan kualitas ikan untuk mempertahankan kepercayaan konsumen. Proses pendeteksian kesegaran ikan, yang umumnya dilakukan secara manual melalui indera manusia, menjadi tidak efektif untuk volume besar karena memakan biaya dan waktu yang tinggi. Penelitian ini bertujuan mengimplementasikan metode *Support Vector Machine* (SVM) dengan *Kernel Radial Basis Function* untuk mendeteksi kualitas ikan segar dan tidak segar berdasarkan citra mata ikan. Dataset yang digunakan sebanyak 1.830 citra, terdiri dari 1.050 citra ikan segar dan 870 citra tidak segar, yang dibagi 80% untuk pelatihan dan 20% untuk pengujian. Model yang dibangun mencapai akurasi sebesar 92,8% dan f1-score 93,4% berdasarkan *confusion matrix*. Pengujian menggunakan *K-Fold Cross-Validation* (K=10) menghasilkan akurasi tertinggi sebesar 94,54% dengan deviasi standar 1,69, menunjukkan kestabilan dan keandalan model. Hasil penelitian ini mendukung penerapan sistem deteksi otomatis berbasis citra mata ikan sebagai alat yang efisien dan akurat untuk menilai kualitas ikan, serta dapat meningkatkan daya saing produk perikanan di pasar global.

Kata kunci : Citra Mata Ikan, Machine Learning, Support Vector Machine (SVM), Kernel Radial Basis Function.

1. PENDAHULUAN

Indonesia merupakan negara kepulauan dengan luas wilayah laut mencapai 5,8 juta km², yang memiliki potensi perikanan besar sebagai sumber daya ekonomi strategis untuk mendukung pembangunan nasional. Sektor perikanan memainkan peran penting dalam meningkatkan kesejahteraan masyarakat, memperkuat ekonomi nasional, serta menjaga kelestarian lingkungan. Selain itu, hasil perikanan juga memberikan kontribusi signifikan dalam menambah devisa negara, menciptakan peluang kerja, serta mendorong produktivitas dan daya saing produk perikanan di pasar global [1].

Sulawesi Tenggara merupakan salah satu wilayah dengan potensi kelautan yang besar. Pada tahun 2021, potensi hasil perikanan di wilayah ini meningkat menjadi 11,60% dari 11,25% pada 2019. Komoditas utama seperti udang, ikan tuna, kakap, tongkol, hingga cumi-cumi banyak dihasilkan di daerah ini, dengan ikan cakalang sebagai unggulan, mencapai volume tangkapan sebesar 21.868 ton bernilai Rp 501 miliar. Produksi ikan ini terus menunjukkan tren peningkatan, seperti pada 2023, di mana sebanyak 5.400 ton ikan cakalang didaratkan di Pelabuhan Perikanan Samudera Kendari. Namun, di tengah peningkatan produksi ini, tantangan dalam menjaga mutu dan kualitas ikan tetap menjadi fokus utama [2].

Jaminan mutu sangat penting dalam menjaga kepercayaan konsumen, terutama di pasar internasional. Beberapa faktor seperti kebersihan, sanitasi, dan pengelolaan suhu penyimpanan ikan menjadi kunci untuk memastikan kesegaran dan

kualitas produk. Ketidaksesuaian dalam standar ini dapat memengaruhi reputasi produk perikanan Indonesia di pasar global. Pengawasan terhadap penggunaan bahan kimia juga diperlukan guna menjamin keamanan konsumen. Produk perikanan yang tidak memenuhi standar dapat menyebabkan penurunan permintaan dan larangan ekspor [3].

Kesegaran ikan umumnya dinilai berdasarkan indikator fisik, seperti warna mata dan insang. Mata ikan yang cerah, menonjol, dan bercahaya menunjukkan kesegaran yang optimal. Namun, metode penilaian manual ini membutuhkan waktu dan biaya yang besar, terutama untuk volume besar, sehingga menjadi kurang efisien. Perubahan pada warna dan kondisi mata ikan, seperti cekung atau memudar, sering kali menjadi indikator penurunan kesegaran, yang berdampak pada penurunan harga jual dan kepercayaan konsumen terhadap produk tersebut [4].

Melihat pentingnya indikator mata ikan sebagai penanda kesegaran, inovasi dalam teknologi deteksi otomatis berbasis citra mata sangat dibutuhkan. Deteksi otomatis ini tidak hanya meningkatkan efisiensi tetapi juga memberikan hasil yang lebih akurat dibandingkan metode manual. Solusi ini diharapkan dapat mendukung keberlanjutan industri perikanan, menjaga reputasi produk perikanan Sulawesi Tenggara, serta meningkatkan daya saing di pasar global dengan memberikan jaminan kualitas yang lebih baik bagi konsumen.

Penelitian untuk deteksi kesegaran ikan sudah pernah dilakukan. Seperti penelitian yang dilakukan Prayogi menggunakan SVM untuk mendeteksi

kesegaran ikan bandeng berbasis citra mata, mencapai rata-rata akurasi 90,2% dengan metode *K-Fold Validation* [6]. Penelitian oleh Ulandari menggunakan metode *Convolutional Neural Network* Arsitektur VGG-16 untuk mengklasifikasikan kesegaran ikan berdasarkan citra mata dengan akurasi mencapai 85,26% [7]. Penelitian Aryawan membandingkan SVM dan CNN dalam klasifikasi ekspresi wajah, di mana SVM lebih unggul dengan akurasi 61,39%, menunjukkan keandalan SVM pada dataset tertentu [8]. Penelitian oleh Putri menggunakan SVM untuk mendeteksi kesegaran ikan berdasarkan citra mata, dengan hasil akurasi 73%. Kekurangan penelitian ini hasil akurasi yang diperoleh tidak begitu baik karena data yang digunakan kurang banyak yaitu 36 data [9].

Berdasarkan penelitian terdahulu ini metode yang dipilih adalah Support Vector Machine (SVM) berdasarkan citra mata ikan. SVM telah terbukti lebih efektif dalam melakukan klasifikasi untuk tugas-tugas seperti ini dibanding metode lain. SVM diterapkan untuk mengenali dan mengkategorikan kualitas ikan cakalang segar berdasarkan citra mata digital. Dalam konteks ini, fungsi Kernel *Radial Basis Function* digunakan untuk meningkatkan kapasitas SVM dalam menangani kompleksitas dan variasi citra. Fungsi ini memungkinkan SVM untuk mengatasi perbedaan subtan yang mungkin muncul dalam citra mata digital ikan cakalang segar.

2. TINJAUAN PUSTAKA

2.1. Ikan Cakalang

Ikan cakalang (*Katsuwonus pelamis*) adalah jenis ikan yang kaya akan nilai gizi dan sangat bermanfaat untuk kesehatan. Ikan ini mengandung omega-3 dalam kadar tinggi, yang merupakan lemak esensial yang mendukung fungsi otak, terutama dalam meningkatkan daya ingat. Karena alasan ini, omega-3 banyak dikonsumsi oleh anak-anak sebagai suplemen untuk mendukung kesehatan mata, kulit, sirkulasi jantung, pembekuan darah, dan kekuatan tulang. Selain itu, omega-3 juga dapat melindungi tubuh dari berbagai penyakit, termasuk kanker pankreas, ovarium, mulut, faring, lambung, kerongkongan, dan usus besar [10]. Ada 2 jenis kualitas kesegaran ikan yaitu ikan segar dan ikan tidak segar.

Ikan segar memiliki beberapa ciri khas, di antaranya matanya yang menonjol, insangnya yang berwarna merah, sisiknya lengkap, dagingnya kenyal, aromanya segar, dan ekornya padat. Mata ikan segar biasanya tampak jernih, bening, dan cembung, yang menandakan bahwa ikan tersebut masih dalam kondisi baik dan baru ditangkap. Penanganan ikan segar dilakukan dengan menjaga suhu tetap rendah, mendekati 0°C, untuk memperlambat proses pembusukan. Penanganan cepat sangat penting untuk menjaga kualitas ikan, sehingga dibutuhkan bahan dan media pendinginan yang efektif untuk menurunkan suhu ikan dengan cepat. Suhu tinggi mempercepat pembusukan ikan, sedangkan suhu rendah dapat menghambat proses tersebut dan menjaga kesegaran ikan lebih lama [11].

Ikan yang tidak segar biasanya memiliki mata yang tampak kusam dan cekung, insang berwarna coklat atau kehitaman, kulit yang tampak kusam dengan sisik yang mudah lepas, serta bau amis yang kuat. Daging ikan menjadi lembek, perutnya kembung, dan lendirnya berubah menjadi kekuningan atau kecoklatan dengan bau yang tidak sedap, menandakan bahwa ikan tersebut sudah tidak layak untuk dikonsumsi. Perbedaan ini menjadi salah satu indikator utama untuk mengevaluasi kesegaran ikan sebelum membelinya atau mengonsumsinya [12].

2.2. Citra digital

Citra digital adalah kumpulan elemen kecil yang disebut piksel (*pixel* atau *picture element*). Setiap piksel direpresentasikan sebagai kotak kecil dengan posisi yang ditentukan oleh koordinat tertentu. Gambar atau citra dapat didefinisikan sebagai pantulan cahaya pada permukaan dua dimensi. Secara matematis, citra merupakan fungsi kontinu dari intensitas cahaya yang berada pada ruang dua dimensi. Terdapat tiga jenis gambar yang sering digunakan dalam pengolahan citra, yaitu gambar berwarna, gambar skala keabuan, dan gambar biner [13].

2.3. Ekstraksi Fitur

Ekstraksi fitur adalah proses penting dalam pengolahan citra yang bertujuan untuk mengambil informasi spesifik yang relevan dari sebuah gambar, seperti pola, warna, atau tekstur, sehingga dapat digunakan untuk analisis lebih lanjut. Proses ini bertujuan untuk merepresentasikan gambar dengan cara yang lebih sederhana namun tetap informatif, mendukung berbagai aplikasi seperti klasifikasi, deteksi objek, dan segmentasi citra. Dalam konteks ini, fitur yang sering diekstrak meliputi fitur warna, bentuk, dan tekstur, yang masing-masing memberikan informasi yang unik dan berguna [14].

Fitur warna diekstrak menggunakan representasi seperti RGB atau HSV, dengan HSV sering menjadi pilihan utama karena mendekati persepsi manusia terhadap warna [15]. *Hue* menggambarkan jenis warna, *saturation* merepresentasikan intensitas warna, dan *value* mencerminkan tingkat kecerahan. Pendekatan ini memberikan analisis warna yang lebih mendalam dan memungkinkan pengelompokan atau pengklasifikasian berdasarkan karakteristik warna dalam citra [16].

Fitur tekstur memberikan informasi tentang pola atau distribusi intensitas piksel dalam gambar. Teknik *Gray Level Co-occurrence Matrix* (GLCM) menghasilkan beberapa fitur tekstur utama, seperti *contrast*, *correlation*, *energy*, dan *homogeneity*. *Contrast* menunjukkan perbedaan intensitas antar piksel, *correlation* mengukur keterkaitan intensitas, *energy* mencerminkan keteraturan pola, dan *homogeneity* mengidentifikasi keseragaman intensitas. Ekstraksi tekstur memainkan peran penting dalam memahami pola visual kompleks, menjadikannya

elemen esensial dalam klasifikasi dan analisis citra [16].

2.4. Klasifikasi Gambar

Klasifikasi gambar adalah proses untuk mengelompokkan dan memberi label pada sekumpulan piksel atau vektor dalam gambar berdasarkan aturan tertentu. Proses ini dapat dilakukan dengan menerapkan satu atau lebih karakteristik, seperti spektral atau tekstur, untuk menentukan kategori atau label yang tepat [17]. Klasifikasi gambar adalah proses mengkategorikan dan menetapkan label pada kelompok piksel atau vektor dalam gambar sesuai dengan aturan tertentu. Beberapa metode yang digunakan dalam klasifikasi dan pengenalan citra meliputi metode pengenalan statistik, pengenalan struktur, jaringan saraf (*neural network*), pengenalan dengan himpunan *fuzzy*, SVM, dan pencocokan *template* [16].

2.5. Support Vector Machine

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang digunakan untuk tugas klasifikasi dan regresi. Algoritma ini bekerja dengan mencari *hyperplane* terbaik yang memaksimalkan margin atau jarak terbesar antara kelas-kelas data yang berbeda. *Hyperplane* ini berfungsi sebagai garis pemisah antara kelas positif dan negatif di dalam ruang dimensi tertentu. SVM memiliki dua jenis utama, yaitu SVM Linear dan SVM Non-Linear [18].

SVM Linear digunakan untuk memisahkan data yang dapat dipisahkan secara linear, yaitu ketika data dari dua kelas berbeda dapat dipisahkan hanya dengan satu garis lurus atau *hyperplane*. Data jenis ini disebut sebagai data terpisah secara linear. *Hyperplane* dalam SVM Linear ditentukan oleh persamaan [19].

$$y = w \cdot x + b \quad (1)$$

Sebaliknya, SVM Non-Linear digunakan untuk data dengan pola kompleks atau tidak teratur yang tidak dapat dipisahkan oleh garis lurus. Dalam kasus ini, SVM menggunakan teknik fungsi kernel untuk memetakan data ke ruang berdimensi lebih tinggi sehingga pola pemisahan menjadi lebih jelas. Fungsi kernel seperti *Radial Basis Function* dan *Polynomial* membantu menemukan *hyperplane* yang mampu memisahkan kelas secara efektif meskipun dengan batasan yang lebih rumit, seperti kurva atau bentuk yang kompleks. Pendekatan ini menjadikan SVM Non-Linear lebih cocok untuk data yang tidak memiliki distribusi linier [19].

2.6. Kernel Radial Basis Function (RBF)

Kernel *Radial Basis Function* (RBF), adalah salah satu jenis kernel yang sering digunakan dalam metode *Support Vector Machine* (SVM) untuk tugas klasifikasi dan regresi, terutama pada data yang tidak dapat dipisahkan secara linier. Kernel ini bekerja dengan memetakan data ke dalam dimensi yang lebih tinggi menggunakan distribusi *Radial Basis Function* (kurva lonceng) untuk mengukur jarak antara

pasangan data. Dengan pemetaan ini, kernel *Radial Basis Function* memungkinkan SVM menemukan *hyperplane* optimal di ruang fitur yang lebih kompleks, sehingga mampu memisahkan data dengan pola yang tidak linier secara efektif [20].

Dalam SVM, kernel *Radial Basis Function* menjadi alat yang andal untuk menangani data dengan batas keputusan non-linier karena fleksibilitasnya dalam memetakan titik-titik data ke ruang berdimensi lebih tinggi. Sebagai contoh, kernel ini dapat mengubah distribusi data dari bidang 2D ke 3D dengan menggeser titik-titik data, seperti titik hijau yang digeser di atas titik merah menggunakan fungsi pemetaan *Radial Basis Function*. Proses ini menciptakan *hyperplane* baru yang memisahkan kelas data secara optimal. Fleksibilitas dan kemampuannya menangani data yang kompleks membuat Kernel *Radial Basis Function* menjadi pilihan umum dalam berbagai aplikasi klasifikasi dan analisis data [20].

2.7. K-fold Cross-Validation

K-fold Cross-Validation adalah metode evaluasi model dalam *Machine Learning* yang bertujuan untuk menilai kinerja model dengan lebih akurat. Teknik ini membantu mengurangi bias dan varians dalam evaluasi model dengan membagi dataset menjadi beberapa subset yang disebut *fold*. Model kemudian dilatih dan diuji secara bergiliran menggunakan setiap *fold* sebagai data uji dan sisanya sebagai data pelatihan. Dengan cara ini, setiap bagian data diuji dan dilatih, memberikan gambaran yang lebih menyeluruh tentang performa model di berbagai subset data [21].

2.8. Confusion Matrix

Confusion Matrix adalah suatu tabel untuk memperlihatkan jumlah pada data pengujian yang terklasifikasi dengan benar dan jumlah pada data pengujian yang salah terklasifikasi. *Confusion Matrix* merupakan suatu teknik analisis prediksi yang berguna untuk membandingkan nilai aktual dengan nilai prediksi dari suatu model. Dengan menggunakan *Confusion Matrix* dapat membuat sebuah matriks evaluasi yang dapat digunakan untuk mengevaluasi performa suatu model klasifikasi yang telah dibuat [22]. Parameter yang digunakan pada data uji yaitu TP (*true positive*), FN (*false negative*), TN (*true negative*) dan FP (*false positive*).

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

Gambar 1. *Confusion Matrix*

Keterangan:

- TP (*True positive*): Merupakan jumlah dari prediksi yang benar-benar positif.
- TN (*True negative*): Merupakan jumlah dari prediksi yang benar-benar negatif.
- FP (*False Positive*): Merupakan jumlah dari prediksi yang salah sebagai positif.
- FN (*False Negative*): Merupakan jumlah dari prediksi yang salah sebagai negatif.

Berdasarkan tabel tersebut dapat dihitung nilai *precision*, *sensitivity*, *recall*, *specificity*, *accuracy* dan *F-measure* menggunakan rumus-rumus berikut:

- Precision* (Presisi). Nilai *precision* mengukur seberapa banyak prediksi positif yang benar dari total prediksi positif yang dilakukan oleh model.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

- Sensitivity* (Sensitivitas atau *Recall*). Nilai *Recall* mengukur seberapa banyak prediksi positif yang benar dari total data yang sebenarnya positif.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

- Specificity* (Spesifisitas). *Specificity* atau Spesifisitas merupakan metrik evaluasi yang menunjukkan seberapa efektif suatu model dalam mengklasifikasikan kelas negatif secara akurat.

$$Specificity = \frac{TN}{TP+FP} \quad (4)$$

- Accuracy* (Akurasi). Nilai *Accuracy* mengukur seberapa banyak prediksi yang benar dari total data yang diprediksi.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

- F-measure* (*F1 Score*). Nilai *F-measure* adalah harmonic mean dari *precision* dan *Recall*.

$$F - measure = \frac{2 \times Precision}{Precision+Recall} \quad (6)$$

3. METODE PENELITIAN

3.1 Observasi Data

Tahap awal dalam penelitian ini, dilakukan dengan cara mengamati atau memantau data ikan cakalang. Data yang diamati meliputi mata ikan cakalang yang menjadi objek penelitian. Data yang diperoleh dari observasi kemudian akan dijadikan sebagai data untuk pengolahan menggunakan metode SVM.

3.2 Pengumpulan Data

Tahap kedua adalah melakukan pengumpulan dataset yang akan digunakan dalam pelatihan menggunakan metode *Support Vector Machine* (SVM). Jumlah dataset yang dihimpun mencapai 1830 citra, yang diperoleh dari mengambil gambar ikan menggunakan kamera smartphone Realme C55 dengan kamera 64MP dan dari Roboflow Data. Data terbagi dalam citra mata ikan segar 1050 citra mata ikan segar dan 780 citra mata ikan tidak segar. Berikut ini contoh citra mata ikan yang akan diolah.




Gambar 2. Citra Mata Ikan Segar dan Tidak Segar

Dari Gambar 2, dapat dilihat bahwa mata ikan segar memiliki warna yang terang dan mengkilap, dengan kecerahan yang tinggi serta kontras yang jelas antara bagian terang dan gelap, menunjukkan tekstur yang tajam dan permukaan yang merata. Sebaliknya, mata ikan tidak segar tampak kusam dan gelap, dengan kecerahan yang rendah dan kurangnya kilau alami, serta tekstur yang kurang terdefinisi, dengan kontras yang lebih rendah dan ketidakrataan pada permukaan mata, yang mengindikasikan penurunan kualitas ikan.

3.3 Perencanaan Alur Sistem

Metode yang umum digunakan untuk perancangan alur sistem secara umum adalah diagram alur (*flowchart*). Diagram alur adalah diagram yang menggambarkan aliran data dan proses dalam suatu sistem dengan menggunakan simbol-simbol tertentu. Berikut adalah gambaran umum dari alur kerja metode *Support Vector Machine* (SVM) dan fungsi Kernel *Radial Basis Function* untuk identifikasi kualitas ikan berdasarkan citra mata ikan.



Gambar 3. Flowchart Sistem Secara Umum

Sistem identifikasi kualitas ikan cakalang segar berbasis citra mata menggunakan metode *Support Vector Machine* (SVM) dengan fungsi Kernel *Radial Basis Function* melibatkan delapan langkah utama.

- a. Inisiasi Sistem: Proses dimulai dengan memulai sistem dan mengunggah citra mata ikan sebagai data masukan.
- b. Pra-Pemrosesan Citra: Citra diproses lebih lanjut meliputi pengubahan ukuran, rotasi, dan konversi ke format HSV untuk ekstraksi warna dan grayscale untuk analisis tekstur.
- c. Ekstraksi Fitur Tekstur: Fitur tekstur diambil dari citra grayscale menggunakan metode Gray-Level Co-occurrence Matrix (GLCM).
- d. Ekstraksi Fitur Warna: Fitur warna diperoleh dari saluran HSV (Hue, Saturation, Value).
- e. Pelatihan SVM: Model SVM dilatih menggunakan fitur yang diekstraksi dan disempurnakan menggunakan GridSearchCV untuk menemukan parameter optimal dengan Kernel *Radial Basis Function*.
- f. Uji Model: Model SVM yang telah dilatih diuji menggunakan data pengujian untuk mengevaluasi akurasi klasifikasi.
- g. Identifikasi Kualitas Ikan: Sistem mengidentifikasi citra mata ikan sebagai segar atau tidak segar berdasarkan hasil klasifikasi.
- h. Tampilan Hasil: Hasil identifikasi ditampilkan kepada pengguna.

3.4 Metode Pengujian *Confusion matrix*

Confusion matrix merupakan salah satu metode evaluasi klasifikasi yang digunakan untuk mengukur kinerja suatu sistem klasifikasi. Dalam konteks sistem identifikasi kualitas ikan cakalang segar berbasis citra mata menggunakan SVM dengan fungsi Kernel *Radial Basis Function*, *confusion matrix* akan digunakan untuk mengevaluasi kinerja sistem dalam mengklasifikasikan citra ikan menjadi kategori kualitas tertentu.

Confusion matrix menyajikan informasi tentang performa model dalam mengklasifikasikan citra ikan ke dalam kategori kualitas tertentu, termasuk jumlah prediksi yang benar dan salah seperti berikut.

- a. *True Positive* (TP) yaitu jumlah ikan cakalang segar yang diklasifikasikan dengan benar sebagai segar.
- b. *False Positive* (FP) yaitu jumlah ikan cakalang segar yang salah diklasifikasikan sebagai segar.
- c. *False Negative* (FN) yaitu jumlah ikan cakalang segar yang diklasifikasikan dengan salah sebagai tidak segar.
- d. *True Negative* (TN) yaitu jumlah ikan cakalang segar yang diklasifikasikan dengan benar sebagai tidak segar.

Setelah *confusion matrix* diperoleh, beberapa metrik evaluasi kinerja dapat dihitung:

- a. Presisi untuk mengukur proporsi dari ikan cakalang segar yang diklasifikasikan dengan benar sebagai segar dari total ikan cakalang segar yang diklasifikasikan sebagai segar.
- b. *Recall* untuk mengukur proporsi dari total ikan cakalang segar yang benar-benar segar yang berhasil terdeteksi oleh model.

- c. *Specificity* untuk mengukur proporsi dari total ikan cakalang segar yang benar-benar tidak segar yang berhasil terdeteksi oleh model.
- d. *F1-Score* adalah harmonik *mean* dari Presisi dan *Recall*. Ini memberikan keseimbangan antara Presisi dan *Recall*.

3.5 Metode Pengujian *K-Fold Validation*

Dalam penelitian ini, metode *K-Fold Cross-Validation* digunakan untuk mengevaluasi performa model secara menyeluruh. Dataset dibagi menjadi beberapa subset atau *folds*, dengan setiap *fold* bergiliran menjadi data uji sementara *fold* lainnya digunakan untuk pelatihan. Proses ini dilakukan sebanyak *K* kali sesuai dengan jumlah *fold* yang ditentukan, sehingga semua data akan digunakan baik untuk pelatihan maupun pengujian. Pada setiap iterasi, model dilatih menggunakan *K-1* subset dan diuji pada 1 subset yang tersisa. Akurasi dihitung untuk setiap *fold*, dan nilai rata-rata akurasi serta deviasi standar dari semua iterasi digunakan untuk menilai performa model. Pendekatan ini memastikan hasil evaluasi lebih akurat dan mengurangi risiko *overfitting*, sehingga model dapat diuji pada berbagai konfigurasi data.

3.6 Perancangan *Interface*

Perancangan antarmuka pengguna (User Interface) adalah proses merencanakan dan membuat tata letak, elemen visual, dan interaksi yang akan muncul saat pengguna berinteraksi dengan suatu sistem atau aplikasi. UI bertujuan untuk menciptakan pengalaman pengguna yang baik, memastikan kejelasan fungsi, dan memudahkan pemahaman terhadap informasi yang disajikan oleh sistem. Selain itu, perancangan UI juga mencakup aspek estetika agar antarmuka terlihat menarik dan profesional. Tampilan utama sistem mewujudkan antarmuka untuk menganalisis citra digital dengan menggunakan metode SVM.

4. HASIL DAN PEMBAHASAN

Bagian ini menjelaskan tahapan implementasi, pengujian, serta evaluasi sistem identifikasi kualitas ikan cakalang segar berdasarkan citra mata menggunakan metode *Support Vector Machine* (SVM) dengan fungsi Kernel *Radial Basis Function*. Proses dimulai dengan penginputan citra, prapemrosesan, ekstraksi fitur warna dan tekstur, serta klasifikasi menggunakan model SVM. Setiap tahapan dianalisis untuk memastikan sistem bekerja dengan optimal dalam mengklasifikasikan citra ikan menjadi dua kategori, yaitu Segar dan Tidak Segar.

4.1. Input Citra

Dari 1830 citra mata ikan dibagi menjadi data pelatihan (80%) yaitu 1464 data dan data pengujian (20%) yaitu 366 untuk memastikan hasil pembagian data konsisten sebelum dilakukan tahap pengujian secara manual. Setelah pelatihan data citra mata ikan yang telah dilakukan, tahapan selanjutnya adalah

pengujian citra/gambar pada sistem *website* yang telah dirancang sebelumnya.

4.2. Pemrosesan Citra

Pada tahap prapemrosesan citra sebelum analisis lebih lanjut, gambar terlebih dahulu diubah ukurannya (*resize*) agar memiliki dimensi yang seragam, sehingga memudahkan proses ekstraksi fitur. Proses berikutnya adalah *remove background*, di mana latar belakang citra dihilangkan sehingga hanya menyisakan objek utama berupa mata ikan untuk dianalisis.



Gambar 3. Ikan Sebelum
Remove Background



Gambar 4. Ikan Setelah
Remove Background

Dari Gambar 3, dapat dilihat bahwa ikan memiliki latar belakang yang tidak terhapus, sehingga objek ikan tercampur dengan elemen lain di sekitarnya. Sementara itu, pada Gambar 4, setelah proses *remove background* dilakukan, ikan tampil lebih jelas dengan latar belakang yang telah dihilangkan, menjadikannya lebih fokus dan mudah untuk dianalisis, menunjukkan hanya objek ikan tanpa gangguan dari latar belakang yang tidak relevan.

4.3. Hasil Ekstraksi Fitur

Setelah citra diproses, sistem akan melakukan ekstraksi fitur dari citra yang telah dipra-pemroses. Pada sistem ini, terdapat dua jenis fitur yang diekstraksi. Pertama, fitur tekstur, yang diambil dari citra *grayscale* menggunakan metode *Gray-Level Co-occurrence Matrix* (GLCM). GLCM menganalisis pola intensitas *pixel* yang berdekatan untuk mendapatkan karakteristik tekstur dari citra, seperti *Contrast*, *dissimilarity*, *Homogeneity*, dan *Energy*.




Gambar 5. Citra *Grayscale*

Pada gambar 5, fitur tekstur seperti *Contrast*, *Dissimilarity*, *Homogeneity*, dan *Energy* dihitung menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM). GLCM adalah matriks yang menggambarkan frekuensi pasangan nilai intensitas piksel muncul pada jarak dan arah tertentu. *Contrast* mengukur perubahan tajam dalam intensitas piksel, *Dissimilarity* menilai ketidakseragaman dari selisih piksel, *Homogeneity* menunjukkan keseragaman area,

dan *Energy* merepresentasikan kekompakan pola tekstur. Fitur-fitur ini penting untuk analisis tekstur dalam klasifikasi citra.

Kedua, fitur warna, diekstraksi dari citra yang telah dikonversi ke ruang warna HSV. Saluran warna H (*Hue*), S (*Saturation*), dan V (*Value*) dihitung untuk mendapatkan distribusi warna dari citra.



Gambar 6. Citra HSV

Pada gambar 6, mengekstrak fitur warna dari gambar dalam ruang warna HSV dengan menghitung statistik dasar dari komponen *Hue*, *Saturation*, dan *Value*. Fungsi ini memisahkan komponen HSV, lalu menghitung nilai rata-rata, minimum, maksimum, variansi, dan normalisasi dari setiap komponen

4.3 Pelatihan Data


Setelah data gambar dan fiturnya terkumpul, model SVM dilatih menggunakan fitur yang diekstraksi. Proses pelatihan ini ditangani oleh GridSearchCV untuk menemukan parameter terbaik dari SVM, di mana kernel *Radial Basis Function* digunakan. Kernel ini membantu memetakan data ke ruang berdimensi lebih tinggi, meningkatkan kemampuan model dalam memisahkan kelas-kelas yang tidak linier. Data yang digunakan untuk melatih model diambil dari data yang sudah dilabeli sebagai segar dan tidak segar, kemudian dipisahkan menjadi *set* pelatihan dan *set* pengujian

4.4. Implementasi Interface


Tahap implementasi antarmuka dirancang agar pengguna dapat dengan mudah mengoperasikan sistem identifikasi kualitas ikan cakalang segar berbasis citra mata. Sistem ini terdiri dari dua *tab* utama, yaitu *Home* dan *Testing*. Pada *tab Home*, pengguna dapat melihat informasi mengenai ciri-ciri ikan cakalang segar dan tidak segar, lengkap dengan gambar ilustrasi untuk memudahkan pemahaman. *Tab* ini berfungsi sebagai pengenalan awal tentang sistem dan membantu pengguna membedakan antara ikan segar dan tidak segar berdasarkan karakteristik mata ikan. Sementara itu, *tab Testing* dirancang khusus untuk melakukan klasifikasi gambar mata ikan yang diunggah oleh pengguna.




Gambar 7. Halaman Utama Sistem Identifikasi Citra Mata Ikan



Gambar 8. Halaman *Testing* Sistem Identifikasi Citra Mata Ikan



Gambar 9. Halaman *Testing* untuk Citra Teridentifikasi Ikan Segar



Gambar 12. Halaman *Testing* untuk Citra

Teridentifikasi Ikan Tidak Segar


Pada halaman utama sistem identifikasi citra mata ikan, terlihat antarmuka yang menampilkan berbagai opsi dan tombol untuk memudahkan pengguna dalam mengakses fitur aplikasi. Selanjutnya, pada halaman *testing*, pengguna dapat mengunggah gambar untuk diuji. Hasil identifikasi akan ditampilkan dengan jelas, menunjukkan apakah gambar mata ikan yang diunggah terdeteksi sebagai ikan segar atau tidak segar, lengkap dengan informasi hasil yang sesuai untuk membantu pengguna dalam penilaian kualitas ikan.

4.5. Hasil Pengujian

Dari 1830 citra mata ikan dibagi menjadi data pelatihan (80%) yaitu 1464 data dan data pengujian (20%) yaitu 366 untuk memastikan hasil pembagian data konsisten sebelum dilakukan tahap pengujian secara manual. Setelah pelatihan data citra mata ikan yang telah dilakukan, tahapan selanjutnya adalah pengujian citra/gambar pada sistem *website* yang telah dirancang sebelumnya.

Setelah sistem berhasil diimplementasikan, pengujian dilakukan untuk mengukur performa model *Support Vector Machine* (SVM) dalam mengklasifikasikan kualitas ikan cakalang. Evaluasi performa melibatkan penggunaan *confusion matrix* dan validasi *K-Fold Cross Validation*.

Confusion matrix dalam kasus ini digunakan untuk mengevaluasi akurasi model dalam mengklasifikasikan gambar ikan ke tiga kategori: Segar dan tidak segar. Matriks ini menunjukkan distribusi prediksi model, baik yang benar maupun salah, untuk setiap kategori.



Gambar 10. Hasil Pengujian dengan *Confusion matrix*

Keterangan:

- True Positives* (TP) adalah jumlah kelas Segar yang diprediksi dengan benar oleh model sebagai Segar yaitu 188.
- True Negatives* (TN) adalah jumlah kelas Tidak Segar yang diprediksi dengan benar oleh model sebagai Tidak Segar yaitu 152.
- False Positives* (FP) adalah jumlah kelas Tidak Segar yang salah diprediksi oleh model sebagai Segar yaitu 17.
- False Negatives* (FN) adalah jumlah kelas Segar yang salah diprediksi oleh model sebagai Tidak Segar yaitu 9.

Berdasarkan keterangan *confusion matrix* tersebut diperoleh:

- Presisi untuk mengukur proporsi dari ikan cakalang segar yang diklasifikasikan dengan benar sebagai segar dari total ikan cakalang segar yang diklasifikasikan sebagai segar. Dengan Rumus (2) dapat dihitung:

$$\text{Precision} = \frac{188}{188+17} = \frac{188}{205} = 0,917 \text{ atau } 91,7\%$$

- Recall* untuk mengukur proporsi dari total ikan cakalang segar yang benar-benar segar yang berhasil terdeteksi oleh model. Dengan Rumus (3) dapat dihitung:

$$\text{Recall} = \frac{188}{188+9} = \frac{188}{197} = 0,954 \text{ atau } 95,4\%$$

- Specificity* untuk mengukur proporsi dari total ikan cakalang segar yang benar-benar tidak segar yang berhasil terdeteksi oleh model. Dengan Rumus (4) dapat dihitung:

$$\text{Specificity} = \frac{152}{152+17} = \frac{152}{169} = 0,899 \text{ atau } 89,9\%$$

- d. *Accuracy*: Rasio dari jumlah prediksi yang benar terhadap total jumlah prediksi. Dengan Rumus (5) dapat dihitung:

$$Accuracy = \frac{188+152}{188+152+17+9} = \frac{340}{366} = 0,928 \text{ atau } 92,8\%$$

- e. *F1-Score* adalah harmonik *mean* dari Presisi dan *Recall*. Ini memberikan keseimbangan antara Presisi dan *Recall*. Dengan Rumus (6) dapat dihitung:

$$F1-Score = \frac{(2 \times 0,917 \times 0,954)}{0,917 + 0,954} = \frac{2 \times 0,874}{1,871} = \frac{1,748}{1,871} = 0,934 \text{ atau } 93,4\%$$

Berdasarkan pengujian data uji, model berhasil mencapai akurasi sebesar 92,8%. Nilai ini menunjukkan bahwa sebagian besar citra mata ikan segar dan tidak segar diklasifikasikan dengan benar. Selain itu, *f1-score* sebesar 93,4% menunjukkan keseimbangan yang baik antara *precision* dan *recall*, membuktikan kemampuan model dalam mendeteksi kedua kategori secara konsisten.

Dalam proses *K-Fold Cross-Validation* yang menggunakan *fold* berbeda-beda, model SVM diuji pada 1 sampai 10 subset data yang berbeda, di mana setiap subset digunakan sebagai data uji secara bergiliran, sementara subset lainnya digunakan sebagai data pelatihan. Tujuan dari teknik ini adalah untuk mengevaluasi performa model secara menyeluruh dan memastikan bahwa model tidak *overfitting* pada data tertentu.

Tabel 1. Perbandingan Pengujian Jumlah *K-Fold Cross-Validation*

Jumlah <i>K-Fold</i>	Akurasi	Deviasi
2	88,36%	1,04
3	91,69%	0,67
4	93,12%	0,85
5	93,77%	0,97
6	93,93%	1,01
7	94,26%	1,40
8	94,37%	1,74
9	94,48%	1,20
10	94,54%	1,69
Rata-rata Akurasi	93,37%	

Berdasarkan hasil *cross-validation*, akurasi tertinggi yaitu 94,54% dengan deviasi standar sebesar 1,69 dari percobaan *K-fold* 10. Untuk rata-rata akurasi yang diperoleh adalah 93,37%. Ini menunjukkan bahwa model memiliki performa yang konsisten di berbagai subset data.

Setelah sistem diuji menggunakan beberapa citra mata ikan, hasil klasifikasi menunjukkan tingkat akurasi yang cukup tinggi. Tabel berikut menyajikan hasil pengujian sistem dengan membandingkan klasifikasi sistem terhadap keterangan sebenarnya dari citra mata ikan cakalang.

Tabel 2. Pengujian Sistem

Nama Citra	Keterangan Citra	Hasil Klasifikasi
data (1).jpg	Mata Ikan Segar	Ikan Segar
data (2).jpg	Mata Ikan Segar	Ikan Segar
data (3).jpg	Mata Ikan Segar	Ikan Segar
data (4).jpg	Mata Ikan Segar	Ikan Segar
data (5).jpg	Mata Ikan Segar	Ikan Segar
data (6).jpg	Mata Ikan Segar	Ikan Segar
data (7).jpg	Mata Ikan Segar	Ikan Segar
data (8).jpg	Mata Ikan Segar	Ikan Tidak Segar
data (9).jpg	Mata Ikan Segar	Ikan Segar
data (10).jpg	Mata Ikan Segar	Ikan Tidak Segar
data (261).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (262).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (263).jpg	Mata Ikan Tidak Segar	Ikan Segar
data (264).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (265).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (266).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (267).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (268).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (269).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar
data (261).jpg	Mata Ikan Tidak Segar	Ikan Tidak Segar

Dari tabel hasil klasifikasi di atas, dapat dilihat bahwa sistem berhasil mengklasifikasikan sebagian besar gambar mata ikan segar dengan benar sebagai Ikan Segar. Namun, ada beberapa kesalahan klasifikasi pada citra, di mana mata ikan segar terklasifikasi sebagai ikan tidak segar. Selain itu, beberapa gambar mata ikan tidak segar terklasifikasi sebagai ikan segar. Kesalahan ini dapat terjadi akibat variasi intensitas cahaya, posisi pengambilan gambar, atau tingkat kemiripan fitur antara mata ikan segar dan tidak segar.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa model *Support Vector Machine* (SVM) dengan ekstraksi fitur warna dan tekstur citra mampu melakukan klasifikasi kualitas ikan cakalang secara efektif, khususnya dalam membedakan ikan segar dan tidak segar, dengan akurasi mencapai 92,8% dan *F1-score* 93,4%. Evaluasi menggunakan *K-Fold Cross-Validation* juga mengindikasikan performa model yang stabil, dengan akurasi tertinggi mencapai 94,54%. Meskipun demikian, untuk meningkatkan akurasi, disarankan menambahkan pengolahan citra dengan *Bounding Box* agar model lebih fokus pada mata ikan dan mengurangi kesalahan klasifikasi. Selain itu, penelitian berikutnya diharapkan dapat mengembangkan aplikasi identifikasi kesegaran ikan berbasis mobile, memudahkan pengguna seperti pedagang atau konsumen untuk melakukan deteksi secara real-time melalui *smartphone*.

DAFTAR PUSTAKA

- [1] P. Perikanan, “„Rencana Strategis Kementerian Kelautan Dan Perikanan Tahun 2020-2024“,” Modal Sosial Dalam Meningkatkan Kesejahteraan Masyarakat Pesisir Di Provinsi Riau, 2020.
- [2] M. Y. Balaka, S. Syamsinar, and B. Sufa, “Daya Saing Komoditi Subsektor Perikanan Terhadap Pertumbuhan Ekonomi Sulawesi Tenggara,” *Sebatik*, vol. 26, no. 2, pp. 472–481, 2022.
- [3] M. Thamrin, M. Tadjuddah, and N. Alimina, “Implementasi Code of Conduct for Responsible Fisheries pada Penanganan Tuna di Pelabuhan Perikanan Samudera Kendari Sulawesi Tenggara,” *JSIPi (Jurnal Sains Dan Inovasi Perikanan)*(Journal Of Fishery Science And Innovation), vol. 8, no. 2, pp. 223–236, 2024.
- [4] H. Honainah and F. F. Romadhoni, “Klasifikasi Kesegaran Ikan Tongkol Berdasarkan Warna Mata Menggunakan Metode Backpropagation,” *Jurnal Penelitian Inovatif*, vol. 2, no. 2, pp. 405–414, 2022.
- [5] H. Winnarko and Y. Mulyani, “Uji coba produk nugget berbahan dasar ikan cakalang (*Katsuwonus pelamis*) dengan penambahan tepung daun kelor (*Moringa oleifera* L),” *JSHP: Jurnal Sosial Humaniora Dan Pendidikan*, vol. 4, no. 1, pp. 13–20, 2020.
- [6] P. Yanuar Risah, C. L. Wibisono, and A. H. Abror, “Deteksi Kesegaran Ikan Bandeng Berbasis Pengolahan Citra Digital,” *REMIK: Riset dan E-Jurnal Manajemen Informatika Komputer*, vol. 4, no. 1, pp. 66–71, 2020.
- [7] R. A. Sutiani, N. Made, S. Ulandari, and R. A. Saputra, “Klasifikasi Kesegaran Ikan Menggunakan Citra Mata dengan Convolutional Neural Network Arsitektur VGG-16,” *JOINTER-JOURNAL OF INFORMATICS ENGINEERING*, vol. 05, no. 02.
- [8] I. P. A. Aryawan, I. N. Purnama, and K. Q. Fredlina, “Analisis Perbandingan Algoritma CNN dan SVM pada Klasifikasi Ekspresi Wajah,” *Jurnal Teknologi Informasi dan Komputer*, vol. 9, no. 4, 2023.
- [9] D. H. Putri, M. Rizka, and Z. K. Simbolon, “Rancang Bangun Sistem Identifikasi Kesegaran Ikan Berdasarkan Citra Mata Menggunakan Support Vector Machine,” *Jurnal Teknologi Rekayasa Informasi dan Komputer*, vol. 6, no. 2, 2023.
- [10] Y. M. T. N. Apituley, L. M. Soukotta, and M. Wattimury, “Penetapan Harga Jual Ikan Segar Dikota Ambon,” *BALOB: Jurnal Pengabdian Masyarakat*, vol. 2, no. 2, pp. 60–66, 2023.
- [11] E. Suprayitno, “Kajian kesegaran ikan di pasar tradisional dan modern Kota Malang,” *JFMR (Journal of Fisheries and Marine Research)*, vol. 4, no. 2, pp. 289–295, 2020.
- [12] F. Marpaung, F. Aulia, and R. C. Nabila, “Computer Vision Dan Pengolahan Citra Digital,” 2022, PUSTAKA AKSARA.
- [13] R. Rahmat, “Identifikasi Nilai Uang Logam Rupiah Berdasarkan Warna Dan Bentuk Objek Berbasis Image Processing,” 2024, Accessed: Dec. 18, 2024. [Online].
- [14] P. Nabilla, M. F. Saputra, and R. A. Saputra, “Perbandingan Ruang Warna RGB, HSV Dan YCbCr Untuk Segmentasi Citra Ikan Kembung Menggunakan K-Means Clustering,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 6, no. 2, pp. 476–481, 2022.
- [15] N. H. Harani and M. Hasanah, *Deteksi Objek dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Berbasis Python*. Kreatif, 2020.
- [16] A. Peryanto, A. Yudhana, and R. Umar, “Image Classification Using Convolutional Neural Network and K Fold Cross Validation,” *J. Appl. Informatics Comput*, vol. 4, no. 1, pp. 45–51, 2020.
- [17] O. O. Palit et al., “Akurasi Metode Mesin Pembelajaran dalam Analisis Variabel Penting Faktor Risiko Sindrom Down,” *The Indonesian Journal of Computer Science*, vol. 13, no. 5, 2024.
- [18] F. Nurfajar, R. Magdalena, and S. SA, “Deteksi Glaukoma pada Citra Fundus Retina menggunakan Metode Local Binary Pattern dan Support Vector Machine,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 4, p. 769, 2022.
- [19] Y. Julianto, D. H. Setiabudi, and S. Rostianingsih, “Analisis Sentimen Ulasan Restoran Menggunakan Metode Support Vector Machine,” *Jurnal Infra*, vol. 10, no. 1, pp. 1–7, 2022.
- [20] A. S. Febrianti, T. A. Sardjono, and A. F. Babgei, “Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine,” *Jurnal Teknik ITS*, vol. 9, no. 1, pp. A118–A123, 2020.
- [21] R. R. R. Arisandi, B. Warsito, and A. R. Hakim, “Aplikasi naïve bayes classifier (nbc) pada klasifikasi status gizi balita stunting dengan pengujian k-fold cross validation,” *Jurnal Gaussian*, vol. 11, no. 1, pp. 130–139, 2022.
- [22] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, vol. 5, no. 2, pp. 697–711, 2021.