

Klasifikasi Kualitas Kopra dengan *Local Binary Pattern* (LBP) dan Hue Saturation Value (HSV) Menggunakan Algoritma *Support Vector Machine* (SVM)

Copra Quality Classification Using Local Binary Pattern (LBP) and Hue Saturation Value (HSV) with Support Vector Machine (SVM) Algorithm

Nur Jayanti Putri S^{*1}, Sulfayanti², Nurhikma Arifin³

^{1,2,3}Informatika, Universitas Sulawesi Barat, Majene, Sulawesi Barat, Indonesia

E-mail : nurjayantinurjayanti2@gmail.com^{*1}, sulfayanti@unsulbar.ac.id²,

nurhikma_arifin@unsulbar.ac.id³

^{*}Corresponding author

Received 10 June 2026; Revised 13 July 2026; Accepted 19 July 2026

Abstrak - Kopra merupakan salah satu komoditas unggulan yang memiliki nilai ekonomi tinggi, namun proses penilaian kualitasnya masih dilakukan dengan metode konvensional sehingga rentan terhadap subjektivitas dan ketidakkonsistenan hasil. Penelitian ini bertujuan untuk membangun model klasifikasi kualitas kopra secara otomatis menggunakan kombinasi fitur tekstur *Local Binary Pattern* (LBP) dan fitur warna *Hue Saturation Value* (HSV) dengan algoritma *Support Vector Machine* (SVM) kernel RBF. Pendekatan ini memanfaatkan teknologi pengolahan citra digital yang mampu membedakan kelas kualitas kopra secara otomatis berdasarkan karakteristik visual tekstur dan warna. Pengujian dilakukan dalam tiga skenario menggunakan masing – masing fitur tekstur, fitur warna serta gabungan keduanya, dengan memvariasikan nilai parameter C dan *gamma* untuk memperoleh kombinasi terbaik. Hasil pengujian menunjukkan bahwa skenario LBP-SVM menghasilkan akurasi sebesar 86,21%, skenario HSV-SVM sebesar 98,12%, dan skenario LBP-HSV-SVM menghasilkan akurasi tertinggi sebesar 98,75% pada parameter C=1 dan *gamma*=0,1. Penggabungan fitur LBP dan HSV terbukti mampu merepresentasikan karakteristik visual kopra dari aspek tekstur dan warna secara bersamaan, sehingga menghasilkan kemampuan klasifikasi antar kelas yang lebih optimal.

Kata kunci - kopra, *Local Binary Pattern*, *Hue Saturation Value*, *Support Vector Machine*, klasifikasi kualitas.

Abstract – Copra is one of the leading commodities with high economic value; however, its quality assessment is still conducted using conventional methods, making it prone to subjectivity and inconsistent results. This study aims to develop an automated copra quality classification model using a combination of *Local Binary Pattern* (LBP) texture features and *Hue Saturation Value* (HSV) color features with a *Radial Basis Function* (RBF) kernel *Support Vector Machine* (SVM) algorithm. This approach utilizes digital image processing technology capable of automatically distinguishing copra quality classes based on visual texture and color characteristics. Testing was conducted in three scenarios using texture features, color features, and a combination of both, respectively, by varying the values of the C and gamma parameters to obtain the best combination. The test results show that the LBP-SVM scenario achieved an accuracy of 86,21%, the HSV-SVM scenario 98,12%, and the LBP-HSV-SVM scenario achieved the highest accuracy of 98,75% at parameters C=1 and gamma=0.1. The combination of LBP and HSV features proved capable of representing the visual characteristics of copra from both texture and color aspects simultaneously, thereby yielding more optimal inter-class classification performance.

Keywords - copra, *Local Binary Pattern*, *Hue Saturation Value*, *Support Vector Machine*, quality classification.

1. PENDAHULUAN

Tanaman kelapa (*Cocos nucifera*) adalah salah satu komoditas yang memiliki nilai ekonomi tinggi karena hampir seluruh bagian tanaman, mulai dari buah, daun, batang, hingga akar, dapat dimanfaatkan oleh manusia [1]. Salah satu manfaat dari kelapa adalah sebagai bahan baku minyak kelapa yaitu kopra. Kopra adalah daging kelapa yang telah dikeringkan dengan menggunakan cara tradisional maupun modern [2]. Kualitas kopra menjadi penentu utama kualitas dan harga minyak kelapa serta produk turunannya di pasar global. Proses penentuan kualitas kopra di tingkat petani hingga saat ini masih sangat bergantung pada metode konvensional. Metode ini memiliki beberapa keterbatasan, terutama karena penilaian sangat subjektif dan sering berbeda antara satu individu dengan yang lain. Selain itu, metode ini juga tidak efisien dalam hal waktu [3].

Perkembangan teknologi pengolahan citra digital memungkinkan proses identifikasi kualitas produk pertanian menjadi lebih mudah dan cepat. Teknologi ini dapat digunakan untuk menilai kualitas kopra secara otomatis, sehingga proses klasifikasi menjadi lebih objektif dan konsisten tanpa bergantung pada metode konvensional. Terdapat beberapa penelitian yang dilakukan terkait klasifikasi kualitas kopra menggunakan berbagai metode dan algoritma yang berbeda. Penelitian oleh [2] mengklasifikasikan kualitas kopra menggunakan ekstraksi fitur warna HSV dan tekstur LBP, kemudian menggunakan algoritma *Nearest Mean Classifier* (NMC) yang mencapai akurasi 90%. Selanjutnya penelitian [4] menggunakan metode *Canny Edge Detection* dan model mencapai akurasi validasi tertinggi 87,50% dan *validation loss* 40,27%. Penelitian [1] memanfaatkan fitur warna RGB dan bentuk untuk membangun sistem prediksi kualitas kopra putih menggunakan algoritma KNN. Penelitian [5] juga mengklasifikasikan jenis kopra menggunakan ekstraksi fitur warna, bentuk dan tekstur dengan algoritma KNN, menghasilkan akurasi 84%.

Pemilihan kopra sebagai objek penelitian didasari oleh variasi warna dan tekstur yang menjadi indikator utama kualitas kopra. Kopra *grade A*, yang memiliki mutu terbaik, berwarna putih kekuningan hingga cokelat muda, teksturnya keras, dan bebas dari jamur. Kopra *grade B* berwarna cokelat agak gelap dan beberapa ketidakrataan permukaan. Sementara itu, kopra *grade C*, sebagai mutu terendah, berwarna cokelat gelap hingga kehitaman dan sering menunjukkan tanda-tanda kerusakan [6]. Perbedaan tekstur dapat ditangkap menggunakan LBP, sedangkan variasi warna dapat dianalisis melalui HSV.


Beberapa riset telah melakukan penggabungan fitur tekstur dengan warna untuk klasifikasi citra. Penelitian dilakukan oleh [7] mengklasifikasi jenis bunga mawar menggunakan fitur warna HSV dan tekstur LBP dengan algoritma KNN dan menghasilkan akurasi tertinggi 87,50%. Penelitian [8] melakukan klasifikasi daging babi, oplosan, dan sapi menggunakan ekstraksi fitur warna HSV dan tekstur LBP dengan algoritma *Random Forest* yang menghasilkan akurasi 78,22%. Sedangkan penelitian [9] mengklasifikasikan citra kue tradisional menggunakan fitur HSV dan LBP dengan algoritma KNN mencapai akurasi sebesar 75%. Penelitian lain oleh [10] kombinasi ekstraksi fitur LBP dan HSV pada klasifikasi kesegaran buah segar dan busuk dengan algoritma *Random Forest* menghasilkan akurasi tertinggi sebesar 95,92% pada nilai *n_estimator* 2000. Penelitian [11] membandingkan metode ekstraksi fitur GLCM dan LBP dalam mengklasifikasikan citra jenis daging kambing, kerbau, dan kuda dengan algoritma SVM, di mana metode LBP menghasilkan akurasi tertinggi sebesar 85,6% dibandingkan GLCM yang hanya menghasilkan akurasi 75,6%. Selain itu, algoritma SVM juga telah banyak digunakan dalam penelitian klasifikasi citra dan terbukti mampu menghasilkan performa yang baik. Penelitian yang dilakukan oleh [12] menggunakan fitur LBP dan HSV pada klasifikasi kesegaran sayur menggunakan algoritma SVM menghasilkan akurasi tertinggi sebesar 65,02% pada nilai *gamma* = 0,04. Penelitian oleh [13] mengklasifikasikan motif batik Indonesia menggunakan ekstraksi fitur LBP dan algoritma SVM menghasilkan akurasi sebesar 88,89%. Penelitian juga dilakukan [14] oleh mengklasifikasikan kualitas ikan cakalang segar dan tidak segar menggunakan ekstraksi

fitur tekstur GLCM dan warna HSV dengan algoritma SVM dan kernel *Radial Basis Function* memperoleh akurasi tertinggi sebesar 94,54%. Selanjutnya, penelitian [15] menunjukkan akurasi tertinggi 86,67% menggunakan SVM dalam klasifikasi kematangan buah alpukat, lebih tinggi dibandingkan KNN.

Berbagai studi menunjukkan bahwa belum terdapat penelitian yang secara khusus mengintegrasikan fitur warna HSV dan fitur tekstur LBP pada citra kopra, kemudian mengklasifikasikannya menggunakan algoritma SVM. Sebagian besar penelitian terdahulu, belum menggabungkan kedua fitur secara optimal untuk klasifikasi SVM. Oleh karena itu, penelitian ini memberikan kontribusi signifikan terhadap pengembangan sistem klasifikasi kualitas kopra berbasis citra digital dengan menggabungkan fitur tekstur lokal LBP dan warna HSV serta memanfaatkan algoritma SVM.

2. METODE PENELITIAN


Metode dalam penelitian ini diawali dengan tahap *preprocessing* citra kopra. Citra RGB terlebih dahulu dikonversi ke *grayscale*, kemudian dilakukan *Otsu thresholding* untuk memisahkan objek kopra dari latar belakang. Hasil *thresholding* selanjutnya diproses melalui operasi morfologi *closing* dan *opening* untuk menyempurnakan area objek. *Mask* hasil morfologi kemudian diaplikasikan pada citra asli untuk menghasilkan citra tersegmentasi yang hanya memuat area kopra tanpa latar belakang, sehingga ekstraksi fitur HSV dan LBP dapat dilakukan secara lebih terfokus. Untuk ekstraksi fitur tekstur, citra kopra hasil segmentasi dalam format *grayscale* diolah menggunakan LBP guna mendapatkan informasi pola tekstur permukaan kopra, yang kemudian disajikan dalam bentuk *histogram* yang telah dinormalisasi. Sedangkan untuk ekstraksi fitur warna, citra kopra hasil segmentasi diubah ke ruang warna HSV, lalu dihitung nilai rata-rata dari setiap kanalnya sebagai representasi warna. Seluruh fitur LBP dan HSV tersebut disusun menjadi vektor numerik sebagai input pada algoritma SVM. Tahap klasifikasi dilakukan menggunakan algoritma SVM untuk membedakan kualitas kopra ke dalam tiga kelas, yaitu *grade_A*, *grade_B*, dan *grade_C*. Penelitian ini diimplementasikan menggunakan bahasa pemrograman *Python* dengan memanfaatkan *Google Colab* sebagai lingkungan pengembangan, serta pustaka *OpenCV* untuk pengolahan citra, *Scikit-learn* untuk proses klasifikasi SVM, dan *NumPy* serta *Pandas* untuk pengelolaan data. Ilustrasi tahapan klasifikasi kualitas kopra ditampilkan pada Gambar 1.



Gambar 1. Alur Diagram Penelitian

2.1 Dataset

Penelitian ini menggunakan 1.952 citra kopra yang diperoleh dari platform *Roboflow* yang dibagi ke dalam tiga kategori kualitas, yaitu *Grade_A*, *Grade_B*, dan *Grade_C*. Data awal terbagi menjadi 1.532 citra data pelatihan (*train*), 360 citra data pengujian (*test*), dan 60 citra data validasi (*valid*). Setiap kelas dalam dataset merepresentasikan kualitas yang berbeda dari segi tekstur maupun warna kopra. Citra kopra dari setiap kategori kualitas dapat dilihat pada Gambar 2 berikut.



Gambar 2. Citra Kopra Setiap Kelas (a) *Grade_A*, (b) *Grade_B*, dan (c) *Grade_C*

2.2 Persiapan Data

Dataset yang digunakan diperoleh dari platform *Roboflow* dalam format *multiclass*, disertai file *classes.csv* yang memuat informasi label kelas setiap citra dalam bentuk *one-hot encoding* dengan kolom *grade_A*, *grade_B*, dan *grade_C*. Pembagian dataset menjadi data latih, uji, dan validasi dilakukan secara otomatis oleh platform *Roboflow* pada saat proses ekspor data. Berdasarkan hasil pemeriksaan, proporsi tiap kelas kualitas kopra relatif seimbang antar subset data, sebagaimana ditunjukkan pada Tabel 1, sehingga pembagian data tersebut tidak menimbulkan bias distribusi kelas yang signifikan terhadap proses pelatihan maupun pengujian model. Tidak ada proses augmentasi citra yang diterapkan pada penelitian ini, sehingga seluruh citra yang digunakan merupakan citra asli hasil pembagian dataset tersebut. Pada penelitian ini hanya digunakan data pelatihan dan data pengujian, sedangkan data validasi tidak digunakan karena evaluasi model dilakukan langsung pada data pengujian.

Tabel 1. Distribusi Dataset

Kelas	Data Training	Data Testing	Data Validasi	Total
<i>Grade_A</i>	432	100	20	552
<i>Grade_B</i>	710	170	20	900
<i>Grade_C</i>	390	90	20	500
Total	1.532	360	60	1.952

Meskipun pembagian data yang dilakukan *Roboflow* menghasilkan proporsi kelas yang relatif seimbang antara data pelatihan dan data pengujian sebagaimana ditunjukkan pada Tabel 1, tetap dilakukan pemeriksaan tambahan terhadap kemungkinan *overlap* antara data pelatihan dan data pengujian sebagai langkah validasi kualitas dataset. Pemeriksaan dilakukan berdasarkan kecocokan nama citra asli (*original filename*), dan ditemukan 41 citra pada data pengujian yang berasal dari sumber gambar yang sama dengan citra pada data pelatihan. Untuk mencegah *data leakage*, ke-41 citra tersebut dihapus dari data pengujian, sehingga jumlah data pengujian yang digunakan pada tahap evaluasi berkurang menjadi 319 citra.


2.3 Preprocessing

Proses preprocessing diawali dengan mengonversi citra RGB menjadi citra *grayscale*. Citra *grayscale* adalah jenis citra yang hanya menyimpan informasi tingkat kecerahan pada setiap pikselnya, di mana masing-masing piksel diwakili oleh satu nilai tunggal dalam

rentang 0 sampai 255. Setiap piksel dalam citra grayscale memiliki rentang nilai dari 0 hingga 255, di mana angka 0 mengindikasikan tingkat kegelapan maksimum (hitam), angka 255 mengindikasikan tingkat kecerahan maksimum (putih), sedangkan nilai-nilai di antara kedua batas tersebut mencerminkan gradasi abu-abu pada skala 8-bit [13]. Untuk mengubah citra RGB menjadi citra grayscale, nilai keabuan setiap piksel dihitung berdasarkan persamaan (1) berikut.

$$Gray = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (1)$$


Nilai Gray yang dihasilkan merupakan perpaduan dari ketiga komponen warna, yaitu R (merah), G (hijau), dan B (biru), yang masing-masing diberi bobot berbeda. Pembobotan ini didasarkan pada tingkat sensitivitas mata manusia yang tidak sama terhadap ketiga warna tersebut. Adapun hasil *preprocessing* citra RGB ke citra *grayscale* ditunjukkan pada Gambar 3 berikut:



Gambar 3. Hasil *Preprocessing* Citra RGB ke Citra *Grayscale*

2.4 Segmentasi

Segmentasi Citra adalah teknik untuk membagi atau memisahkan suatu citra menjadi beberapa daerah (*region*) atau beberapa objek dimana setiap daerah memiliki kemiripan atribut [16]. Tahapan segmentasi pada penelitian ini terdiri atas tiga proses utama, yakni Otsu thresholding, operasi morfologi, dan identifikasi objek. Visualisasi dari rangkaian proses tersebut disajikan pada Gambar 4.



Gambar 4. Proses Segmentasi Citra

2.3.1 Thresholding Otsu

Citra *grayscale* yang telah melalui tahap *preprocessing* selanjutnya diolah dengan metode *thresholding* Otsu pada tahap ini. Metode tersebut berfungsi menentukan nilai ambang batas secara otomatis guna mengubah citra *grayscale* menjadi citra biner. Dalam citra biner, setiap piksel hanya memiliki dua kemungkinan nilai, yakni 0 atau 255, nilai 0 menandai area latar belakang, sedangkan nilai 255 menandai area objek yang berhasil dikenali..

2.3.2 Morfologi Citra

Setelah proses *thresholding* selesai, dilakukan operasi morfologi guna menyempurnakan hasil segmentasi yang telah diperoleh. Dua jenis operasi morfologi diterapkan pada citra, yaitu *closing* dan *opening*. Operasi *closing* dijalankan melalui urutan dilasi yang kemudian diikuti erosi. Persamaan yang merepresentasikan operasi tersebut ditunjukkan sebagai berikut::

$$X \bullet B = (X \oplus B) \ominus B \quad (2)$$

Persamaan (2) menunjukkan operasi *closing*, terlihat bahwa set x mengalami proses dilasi oleh elemen B terlebih dahulu, baru kemudian hasilnya melalui proses erosi. Mekanisme ini berfungsi menutup lubang-lubang kecil atau celah yang terdapat pada objek di dalam citra. Berkebalikan dengan *closing*, operasi *opening* mendahulukan proses erosi sebelum dilasi.

Fungsi dari operasi ini adalah menghilangkan noise atau titik-titik kecil yang bukan bagian dari objek utama, sebagaimana dirumuskan pada persamaan berikut:

$$X \circ B = (X \theta B) \oplus B \quad (3)$$

Persamaan (3) menunjukkan bahwa set x terlebih dahulu mengalami erosi oleh elemen B , kemudian hasil erosi tersebut didilasi kembali, sehingga noise berukuran kecil dapat tereliminasi tanpa mengubah bentuk asli dari objek utama.

2.3.3 Masking

Proses *masking* dilakukan dengan mengaplikasikan citra biner hasil operasi morfologi sebagai *mask* pada citra asli. *Mask* tersebut bernilai 255 pada piksel yang teridentifikasi sebagai objek kopra dan bernilai 0 pada piksel latar belakang. Hasil dari proses ini adalah dua citra tersegmentasi, yaitu citra RGB *masked* yang digunakan untuk ekstraksi fitur HSV, dan citra *grayscale masked* yang digunakan untuk ekstraksi fitur LBP. Pendekatan ini memastikan bahwa fitur yang diekstrak benar-benar hanya berasal dari area objek kopra tanpa kontribusi dari latar belakang.

2.5 Ekstraksi Fitur


Ekstraksi fitur merupakan salah satu tahapan dalam pengolahan citra yang bertujuan untuk memperoleh informasi penting berupa ciri atau karakteristik tertentu dari suatu citra. Proses ini dilakukan agar objek dalam citra dapat direpresentasikan secara lebih jelas melalui informasi yang dapat digunakan untuk mendeskripsikan, membedakan, dan menginterpretasikan objek tersebut [17]. Pada penelitian ini, fitur yang diekstraksi terdiri atas fitur tekstur *Local Binary Pattern* (LBP) dan fitur warna *Hue, Saturation, Value* (HSV). Ekstraksi fitur dilakukan agar setiap citra kopra dapat direpresentasikan dalam bentuk nilai numerik yang dapat digunakan pada proses klasifikasi.

2.4.1 Local Binary Pattern (LBP)

LBP adalah salah satu metode untuk menganalisis tekstur citra yang pertama kali diperkenalkan oleh Timo Ojala dan David Harwood pada tahun 1992. Cara kerja metode ini dilakukan dengan membandingkan nilai intensitas piksel yang berada di tengah dengan nilai intensitas piksel-piksel di sekitarnya. Dari proses perbandingan tersebut akan terbentuk pola biner, kemudian pola tersebut diubah ke dalam bentuk nilai desimal. Nilai inilah yang digunakan untuk merepresentasikan karakteristik tekstur lokal pada suatu citra [18]. Pada penelitian ini LBP untuk memperoleh informasi tekstur lokal pada citra kopra. Untuk menghitung LBP pada suatu piksel dengan tetangga sebanyak P dapat dinyatakan pada persamaan (4) berikut:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) \times 2^p \quad (4)$$


Dengan g_c sebagai intensitas piksel pusat, g_p sebagai intensitas piksel tetangga, P sebagai jumlah piksel tetangga, dan R sebagai radius ketetanggaan. Fungsi $s(x)$ bernilai 1 apabila $x \geq 0$ dan bernilai 0 apabila $x < 0$. Dalam penelitian ini digunakan parameter $P = 8$ dan $R = 1$, sehingga setiap piksel pusat dibandingkan dengan delapan piksel tetangga pada radius satu piksel. Hasil perbandingan tersebut membentuk pola biner yang kemudian dikonversi menjadi nilai desimal. Pada metode Uniform LBP, pola biner yang terbentuk selanjutnya dikelompokkan berdasarkan jumlah transisi antara nilai 0 dan 1. Pola dengan jumlah transisi tidak lebih dari dua disebut sebagai *uniform pattern*, sedangkan pola lainnya dikelompokkan ke dalam satu kategori *non-uniform*. Pendekatan ini menghasilkan representasi tekstur yang lebih ringkas dan lebih stabil terhadap variasi lokal pada citra. Karena metode yang digunakan adalah uniform LBP, hasil ekstraksi tekstur direpresentasikan dalam bentuk *histogram* sebanyak 10 fitur, yaitu LBP_0 sampai LBP_9 . Histogram tersebut kemudian dinormalisasi agar nilai fitur memiliki skala yang seimbang sebelum digunakan pada tahap klasifikasi. Proses ekstraksi fitur tekstur menggunakan metode LBP dapat dilihat pada Gambar 5.



Gambar 5. Hasil Ekstraksi Fitur
Tekstur LBP

2.4.2 Hue Saturation Value (HSV)

Ruang warna HSV merupakan model warna yang merepresentasikan warna berdasarkan tiga komponen utama, yaitu *Hue* sebagai penanda jenis warna, *Saturation* sebagai tingkat kejenuhan warna, dan *Value* sebagai tingkat kecerahan. Dibandingkan dengan ruang warna RGB (*Red, Green, Blue*), ruang warna HSV memiliki kelebihan dalam memisahkan informasi warna dari tingkat kecerahan secara lebih efektif. Pemisahan ini menjadi penting pada pengolahan citra kopra, karena variasi kualitas kopra dapat terlihat dari perbedaan warna, kejenuhan, dan kecerahan pada permukaan objek [19]. Pada tahap ini, citra hasil *cropping* dikonversi dari RGB ke HSV. Proses konversi ruang warna RGB ke HSV dapat dilihat pada Gambar 6.



Gambar 6. Hasil Konversi Ruang
Warna RGB ke HSV

Setelah konversi dilakukan, setiap kanal HSV dipisahkan kemudian diekstraksi tiga statistik, yaitu nilai rata-rata (*mean*), standar deviasi (*std*), dan kemiringan distribusi (*skewness*) sehingga diperoleh sembilan fitur, yaitu *Mean_H*, *Std_H*, *Skew_H*, *Mean_S*, *Std_S*, *Skew_S*, *Mean_V*, *Std_V*, dan *Skew_V*. Kesembilan fitur tersebut digunakan sebagai representasi warna citra kopra dan disimpan bersama label per kelas untuk tahap klasifikasi menggunakan SVM.

2.6 Klasifikasi Support Vector Machine (SVM)

SVM adalah algoritma klasifikasi yang bekerja dengan mencari bidang pemisah (*hyperplane*) terbaik untuk membedakan data ke dalam dua kelas atau lebih. Konsep utama SVM adalah memaksimalkan jarak (*margin*) antara *hyperplane* dengan data terdekat dari setiap kelas, karena semakin besar *margin* yang diperoleh maka semakin baik model dalam mengenali data baru yang belum pernah dilihat sebelumnya. Tidak seperti metode yang mengandalkan kemiripan antar data, SVM berfokus pada posisi data terhadap *hyperplane*. Algoritma ini cocok digunakan pada data dengan jumlah fitur yang besar serta dapat menangani pemisahan data secara linear maupun *non-linear* melalui teknik *kernel*, seperti *kernel Radial Basis Function* (RBF), *polynomial*, dan jenis kernel lainnya [20].

Fitur hasil ekstraksi yang terdiri atas 9 fitur HSV (*Mean_H*, *Std_H*, *Skew_H*, *Mean_S*, *Std_S*, *Skew_S*, *Mean_V*, *Std_V*, *Skew_V*) dan 10 fitur LBP (*LBP_0* hingga *LBP_9*) digunakan sebagai masukan pada algoritma SVM. Pada penelitian ini, algoritma SVM dikonfigurasi menggunakan kernel RBF yang efektif dalam menangani data *non-linear* dengan memetakan data ke ruang fitur berdimensi lebih tinggi sehingga memungkinkan pemisahan kelas yang kompleks. Nilai kernel RBF dapat diperoleh melalui perhitungan pada persamaan (5) berikut:

$$K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (5)$$

Dengan $x - x'$ merupakan vektor fitur, $\|x - x'\|^2$ menunjukkan jarak *euclidean* kuadrat antara dua vektor fitur, sedangkan γ merupakan parameter yang mengatur pengaruh jarak antar data terhadap nilai kernel. Parameter C berfungsi sebagai pengatur toleransi model terhadap kesalahan klasifikasi, di mana nilai C yang besar memperkecil toleransi kesalahan namun berisiko menyebabkan *overfitting*. Parameter *gamma* mengatur pengaruh setiap titik data terhadap batas keputusan, di mana nilai *gamma* yang terlalu kecil membuat model sulit menangkap pola non-linear. Pengujian parameter dilakukan dengan beberapa variasi nilai C, yaitu 1, 5, dan 10, serta nilai *gamma* pada rentang 10^{-1} hingga 10^{-5} .

2.7 Evaluasi

Hasil evaluasi diperoleh melalui tiga skenario pengujian, yaitu LBP-SVM, HSV-SVM, dan LBP-HSV-SVM, yang kemudian dianalisis menggunakan *Confusion Matrix*. *Confusion Matrix* adalah metode evaluasi model klasifikasi yang berbentuk tabel matriks untuk membandingkan hasil prediksi model dengan data aktual. Matriks ini memberikan gambaran detail mengenai prediksi yang benar dan salah untuk setiap kelas, sehingga memudahkan analisis performa model SVM. Performa model SVM dapat dihitung menggunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score* yang dapat dihitung menggunakan Persamaan (5), (6), (7), dan (8) berikut :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$


$$F1 - Score = \frac{2 \times Recall \times Precision}{Recal + precision} \quad (9)$$

Keterangan :

True Positive (TP) : Jumlah data yang bernilai positif dan diprediksi benar positif
False Positive (FP) : Jumlah data yang bernilai negatif tetapi diprediksi positif
False Negative (FN) : Jumlah data yang bernilai positif dan diprediksi benar negatif
True Negative (TN) : Jumlah data yang bernilai negatif tetapi diprediksi negatif


3. HASIL DAN PEMBAHASAN

Hasil pengujian klasifikasi kualitas kopra dilakukan dengan mengekstraksi fitur tekstur menggunakan LBP fitur warna menggunakan HSV, yang selanjutnya diklasifikasikan menggunakan algoritma SVM dengan kernel RBF. Pengujian dilakukan dalam tiga skenario kombinasi fitur, dengan memvariasikan nilai parameter C dan *gamma* untuk menemukan parameter optimal pada masing-masing skenario. Fitur LBP membantu model mengenali pola permukaan atau tekstur kopra, sedangkan fitur HSV membantu model menangkap perbedaan warna yang menjadi salah satu indikator kualitas kopra. Penggunaan kernel RBF pada SVM mendukung model dalam mempelajari pola data yang bersifat non-linear. Dengan demikian, pengujian ini bertujuan untuk menentukan skenario fitur dan parameter terbaik dalam klasifikasi kualitas kopra secara lebih akurat dan andal.



Gambar 7. Grafik akurasi hasil tuning parameter C dan gamma pada klasifikasi menggunakan LBP

Pada Gambar 7 pengujian performa hasil klasifikasi dilakukan dengan fitur tekstur LBP menggunakan algoritma SVM dengan kernel RBF. Akurasi terbaik dicapai pada $C=10$ dengan $\gamma=0,1$ sebesar 86,21%, di mana nilai akurasi yang sama juga diperoleh pada $C=5$ dengan $\gamma=0,01$. Sementara itu, $C=5$ dan $C=1$ pada $\gamma=0,1$ menghasilkan akurasi 85,58%, dan pada $\gamma=0,01$ performa menurun ke rentang 55,17% – 85,58%. Karena terdapat dua konfigurasi parameter yang menghasilkan akurasi yang sama, pemilihan parameter terbaik didasarkan pada prinsip kesederhanaan model [21]. Parameter $C=10$ dengan $\gamma=0,1$ dipilih karena menunjukkan stabilitas yang lebih baik, di mana seluruh variasi nilai C pada γ tersebut menghasilkan akurasi yang konsisten, berbeda dengan $\gamma=0,01$ yang mengalami penurunan signifikan pada $C=1$ hingga 55,17%. Penurunan lebih tajam terjadi pada $\gamma=0,001$ dengan akurasi antara 42,63% hingga 80,56%. Nilai γ yang sangat kecil, yaitu 0,0001 dan 0,00001 menyebabkan seluruh kombinasi parameter menghasilkan akurasi di 47,34% dan 28,21%. Hasil ini menunjukkan bahwa fitur LBP memiliki sensitivitas yang cukup tinggi terhadap pengaturan γ . Jika γ terlalu kecil, model gagal menangkap variasi tekstur yang menjadi ciri penting dalam proses klasifikasi.




Gambar 8. Hasil *Confusion matrix* klasifikasi menggunakan LBP dan SVM dengan Kernel RBF

Gambar 8 menunjukkan *confusion matrix* dari hasil klasifikasi dilakukan dengan fitur tekstur LBP menggunakan algoritma SVM. Matriks ini memberikan gambaran kinerja model dalam mengklasifikasikan tiga jenis kualitas kopra : *Grade_A*, *Grade_B*, dan *Grade_C*. Model berhasil mengklasifikasikan sebanyak 72 sampel kelas *Grade_A* dengan benar, dengan 6 sampel yang salah diklasifikasikan ke kelas *Grade_B* dan tidak ada sampel yang salah diklasifikasikan ke kelas *Grade_C*. Untuk kelas *Grade_B*, model mampu mengklasifikasikan 126 sampel secara tepat, sementara terdapat 16 sampel yang salah diklasifikasikan sebagai *Grade_A* dan 9 sampel salah diklasifikasikan sebagai *Grade_C*. Adapun pada kelas *Grade_C*, sebanyak 77 sampel

berhasil diklasifikasikan dengan benar, namun terdapat 9 sampel yang salah diklasifikasikan sebagai *Grade_B* dan 4 sampel salah diklasifikasikan sebagai *Grade_A*.

Secara keseluruhan, *confusion matrix* menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup baik, dengan sebagian besar nilai terkonsentrasi pada tempat prediksi yang benar. Hal ini sejalan dengan nilai akurasi yang diperoleh sebesar 86,21%, yang menunjukkan bahwa model LBP dan SVM cukup andal dalam mengklasifikasikan kualitas kopra ke dalam tiga kelas. Kesalahan klasifikasi terbanyak terjadi pada kelas *Grade_B* yang salah diprediksi sebagai *Grade_A* sebanyak 16 sampel, mengindikasikan bahwa fitur tekstur LBP saja belum sepenuhnya mampu membedakan karakteristik visual antara kopra *Grade_B* dan *Grade_C* yang kemungkinan memiliki pola tekstur yang cukup serupa. Hal ini menunjukkan bahwa meskipun performa model tergolong baik, masih terdapat tantangan dalam membedakan kelas-kelas yang memiliki kemiripan pola tekstur secara visual.

Selain akurasi, dilakukan evaluasi menggunakan metrik *Precision*, *Recall*, dan *F1-Score* untuk mengukur performa model secara lebih rinci pada tiap kelas. Pada skenario LBP dan SVM ini, *F1-Score* berkisar antara 0,85 hingga 0,88. Kelas *Grade_A* memiliki *precision* terendah 0,78, yang mengindikasikan banyak citra dari kelas lain yang salah diklasifikasikan sebagai *Grade_A*, sementara kelas *Grade_B* memiliki *recall* terendah 0,83, sejalan dengan hasil *confusion matrix* yang menunjukkan 16 sampel *Grade_B* salah diprediksi sebagai *Grade_A*. Hal ini menunjukkan bahwa fitur tekstur LBP saja belum cukup untuk membedakan *Grade_A* dan *Grade_B* secara konsisten.




Gambar 9. Grafik akurasi hasil tuning parameter C dan gamma pada klasifikasi menggunakan HSV

Pada Gambar 9 pengujian performa hasil klasifikasi dilakukan dengan fitur warna HSV menggunakan algoritma SVM dengan kernel RBF. Akurasi tertinggi diperoleh pada nilai $C=10$ dan $\gamma=0,1$ sebesar 98,12%. Kombinasi $C=1$ dan $\gamma=0,1$ menghasilkan akurasi yang sebesar 97,18%, sedangkan $C=5$ dan $\gamma=0,1$ menghasilkan akurasi sedikit lebih tinggi sebesar 97,81%. Kondisi ini menunjukkan bahwa pada $\gamma=0,1$, peningkatan nilai C dari 1 ke 10 tetap memberikan pengaruh terhadap akurasi, meskipun peningkatannya relatif kecil, yang mengindikasikan bahwa fitur HSV telah cukup mampu memisahkan antar kelas sehingga model tidak terlalu bergantung pada nilai C yang besar.

Pada $\gamma=0,01$, akurasi mengalami penurunan dengan nilai terbaik sebesar 97,18% pada $C=1$ dan $C=10$, sedangkan $C=5$ menghasilkan akurasi 96,87%. Penurunan lebih signifikan terjadi pada $\gamma=0,001$ dengan rentang akurasi 29,65% hingga 97,18%. Kondisi menunjukkan bahwa parameter γ mengontrol pengaruh setiap titik data terhadap batas keputusan, di mana nilai γ yang terlalu kecil menyebabkan model tidak mampu menangkap pola *non-linear* secara optimal. Penurunan paling ekstrem terjadi pada $\gamma=0,0001$ dan $\gamma=0,00001$

dengan akurasi antara 28,21% hingga 57,05%, yang mengindikasikan model gagal membentuk batas keputusan yang bermakna. Dengan demikian, pemilihan kombinasi parameter C dan γ yang tepat sangat menentukan performa klasifikasi fitur HSV menggunakan SVM kernel RBF.




Gambar 10. Hasil *Confusion matrix* klasifikasi menggunakan HSV dan SVM dengan Kernel RBF

Gambar 10 menunjukkan *confusion matrix* dari hasil klasifikasi dilakukan dengan fitur warna HSV menggunakan algoritma SVM. Matriks ini memberikan gambaran kinerja model dalam mengklasifikasikan tiga jenis kualitas kopra : *Grade_A*, *Grade_B*, dan *Grade_C*. Model berhasil mengklasifikasikan sebanyak 78 sampel kelas *Grade_A* secara tepat. Untuk kelas *Grade_B*, model mampu mengklasifikasikan 145 sampel secara tepat, sementara terdapat 5 sampel yang salah diklasifikasikan sebagai *Grade_A* dan 1 sampel salah diklasifikasikan sebagai *Grade_C*. Adapun pada kelas *Grade_C*, model menunjukkan performa yang sangat baik dengan 90 sampel berhasil diklasifikasikan secara tepat.

Secara keseluruhan, *confusion matrix* HSV dan SVM menunjukkan peningkatan performa yang cukup signifikan dibandingkan skenario LBP dan SVM sebelumnya. Hal ini terlihat dari berkurangnya jumlah kesalahan klasifikasi pada setiap kelas, terutama pada kelas *Grade_B* yang sebelumnya mengalami 25 kesalahan kini hanya mengalami 6 kesalahan. Nilai akurasi yang diperoleh pada skenario ini sebesar 98,12%, lebih tinggi dibandingkan skenario LBP dan SVM yang hanya mencapai 86,21%. Hasil ini menunjukkan bahwa fitur warna HSV memiliki kemampuan yang lebih baik dalam membedakan karakteristik visual antar kelas kualitas kopra. Meskipun demikian, masih terdapat kesalahan klasifikasi pada *Grade_B*, yang mengindikasikan bahwa fitur warna saja belum sepenuhnya optimal dalam membedakan kedua kelas tersebut.


Berdasarkan metrik *Precision*, *Recall*, dan *F1-Score*, performa model pada skenario HSV dan SVM meningkat signifikan dibandingkan LBP, dengan *F1-Score* di atas 0,97 untuk seluruh kelas. Kelas *Grade_B* mencapai *precision* sempurna 1,00, namun *recall* sedikit lebih rendah 0,96, sejalan dengan hasil *confusion matrix* yang menunjukkan masih terdapat 6 sampel *Grade_B* yang salah diklasifikasikan ke kelas lain, meskipun tidak ada sampel dari kelas lain yang salah diklasifikasikan sebagai *Grade_B*. Hal ini mengindikasikan bahwa fitur warna HSV mampu membedakan kelas *Grade_B* dengan cukup baik, namun sebagian kecil citra dengan variasi warna yang mendekati *Grade_A* atau *Grade_C* masih menyebabkan kesalahan klasifikasi.



Gambar 11. Grafik akurasi hasil tuning parameter C dan gamma pada klasifikasi menggunakan kombinasi LBP dan HSV

Pada Gambar 11 pengujian performa hasil klasifikasi dilakukan dengan fitur LBP dan HSV menggunakan algoritma SVM dengan kernel RBF. Penggabungan kedua fitur terbukti menghasilkan performa terbaik di antara ketiga skenario pengujian. Akurasi tertinggi diperoleh pada $\gamma=0,1$ dengan nilai 98,75% yang dicapai pada ketiga variasi C yaitu $C=1$, $C=5$, dan $C=10$. Kondisi ini menunjukkan bahwa kombinasi fitur HSV dan LBP telah menghasilkan representasi data yang mampu memisahkan antar kelas dengan sangat baik sehingga batas pemisah antar kelas terbentuk dengan sangat baik tanpa dipengaruhi oleh perubahan nilai C. Meskipun ketiga nilai C menghasilkan akurasi yang sama, dipilih $C=1$ sebagai parameter terbaik karena nilai C yang lebih kecil menghasilkan *margin* yang lebih besar sehingga model lebih general dengan risiko *overfitting* yang lebih rendah. Hal ini sejalan dengan pernyataan [21] bahwa parameter C mengontrol keseimbangan antara kompleksitas model dan toleransi terhadap kesalahan klasifikasi, di mana nilai C yang lebih kecil lebih diutamakan ketika menghasilkan performa yang setara.

Pada $\gamma=0,01$, akurasi masih cukup tinggi dengan nilai terbaik 98,75% pada $C=10$ dan $C=5$. Namun penurunan performa mulai terlihat seiring mengecilnya nilai γ , khususnya pada $\gamma=0,001$ dengan rentang akurasi 52,66% hingga 95,92%. Penurunan paling drastis terjadi pada $\gamma=0,0001$ dan $\gamma=0,00001$ dengan akurasi antara 28,21% hingga 64,58%, yang mengindikasikan model gagal menangkap pola *non-linear* pada data. Dengan demikian, meskipun kombinasi fitur HSV dan LBP mampu meningkatkan performa klasifikasi secara signifikan, pemilihan nilai γ yang tepat tetap menjadi faktor penentu keberhasilan model SVM.










Gambar 12. Hasil *Confusion matrix* klasifikasi menggunakan HSV dan LBP menggunakan SVM dengan Kernel RBF

Gambar 12 menunjukkan *confusion matrix* dari hasil klasifikasi dilakukan dengan fitur LBP dan HSV menggunakan algoritma SVM kernel RBF. Matriks ini memberikan gambaran kinerja model dalam mengklasifikasikan tiga jenis kualitas kopra : *Grade_A*, *Grade_B*, dan

Grade_C. Model berhasil mengklasifikasikan sebanyak 78 sampel kelas *Grade_A* dengan benar, tanpa adanya satu pun sampel yang salah diklasifikasikan ke kelas *Grade_B* maupun *Grade_C*. Untuk kelas *Grade_B*, model mampu mengklasifikasikan 147 sampel, sementara terdapat 3 sampel yang salah diklasifikasikan sebagai *Grade_A* dan 1 sampel salah diklasifikasikan sebagai *Grade_C*. Adapun pada kelas *Grade_C*, model menunjukkan performa yang sangat baik dengan 90 sampel berhasil diklasifikasikan dengan tepat.

Evaluasi *Precision*, *Recall*, dan *F1-Score* pada skenario kombinasi LBP dan HSV menunjukkan performa terbaik secara keseluruhan, dengan *F1-Score* mencapai 0,98–0,99 pada seluruh kelas. Kelas *Grade_B* tetap menjadi kelas dengan *recall* terendah 0,97 dibandingkan *Grade_A* dan *Grade_C* yang mencapai *recall* sempurna 1,00, meskipun jumlah kesalahan berkurang menjadi hanya 4 dari 151 sampel dibandingkan skenario LBP maupun HSV secara terpisah. Konsistensi pola ini pada ketiga skenario menunjukkan bahwa kelas *Grade_B*, sebagai kelas dengan jumlah data terbanyak 151 citra dan berada di antara karakteristik *Grade_A* dan *Grade_C*, secara alami lebih rentan mengalami kesalahan klasifikasi dibandingkan kedua kelas lainnya, khususnya pada kondisi citra dengan kualitas kopra yang berada pada batas antar-grade. Untuk memberikan gambaran yang lebih rinci mengenai hasil klasifikasi, Tabel 2 menyajikan sebagian sampel data pengujian beserta label aktual dan label prediksi model pada skenario LBP-HSV-SVM dengan parameter $C=1$ dan $\gamma=0,1$.

Tabel 2. Sampel Gambar yang Salah Prediksi pada Skenario Gabungan LBP dan HSV

Data	Citra LBP	Citra HSV	Label Aktual	Label Prediksi
			<i>grade_B</i>	<i>grade_A</i>
			<i>grade_B</i>	<i>grade_C</i>
			<i>grade_B</i>	<i>grade_A</i>
			<i>grade_B</i>	<i>grade_A</i>

Tabel 2 menyajikan citra yang mengalami kesalahan klasifikasi pada skenario pengujian gabungan fitur HSV dan LBP, di mana keempat sampel yang memiliki label aktual *grade_B* diprediksi sebagai *Grade_C* dan *Grade_A*. Kesalahan prediksi ini terjadi karena karakteristik warna dan tekstur yang dimiliki oleh citra *Grade_B* menunjukkan kemiripan yang tinggi dengan kelas lain. Pada citra pertama, warna permukaan kopra cenderung lebih gelap dengan dominasi warna coklat tua serta tekstur yang relatif kasar, sehingga fitur HSV dan LBP yang diekstraksi lebih menyerupai karakteristik *Grade_C*. Sementara itu, pada citra kedua, warna objek tampak lebih cerah dengan dominasi warna putih krem dan tekstur yang lebih halus, sehingga memiliki kemiripan dengan karakteristik *Grade_A*. Hal ini mengindikasikan bahwa batas pemisah antara *Grade_B* dengan *Grade_A* maupun *Grade_C* tidak selalu tegas secara visual, terutama pada kopra yang berada di rentang kualitas peralihan antar kelas. Meskipun demikian, dengan hanya 4 kesalahan dari 319 data pengujian, model HSV dan LBP menggunakan SVM kernel RBF terbukti sangat efektif dalam mengklasifikasikan kualitas kopra dengan akurasi 98,75%.

4. KESIMPULAN

Penelitian ini berhasil membangun sistem klasifikasi kualitas kopra secara otomatis dengan mengintegrasikan fitur tekstur LBP dan fitur warna HSV yang diklasifikasikan menggunakan algoritma SVM kernel RBF. Berdasarkan hasil pengujian kombinasi fitur LBP dan HSV memberikan performa terbaik dengan akurasi mencapai 98,75% pada nilai parameter $C=1$ dan $\gamma=0,1$, mengungguli penggunaan masing-masing fitur secara terpisah. Temuan ini membuktikan bahwa penggabungan informasi tekstur dan warna mampu meningkatkan kemampuan model dalam membedakan tiga kelas kualitas kopra, yaitu *Grade_A*, *Grade_B*, dan *Grade_C*, secara lebih akurat. Ke depannya, penelitian selanjutnya disarankan mencoba metode *deep learning* sebagai bahan perbandingan performa dan pengembangan sistem pendeteksi kualitas kopra secara otomatis berbasis citra agar dapat digunakan langsung di lapangan.

REFERENSI

- [1] R. Rahayu Marlis, Abdullah, and F. Yunita, "Sistem Prediksi Kualitas Kopra Putih Menggunakan k-Nearest Neighbor (k-NN)," *Sist. J. Sist. Inf.*, vol. 10, no. 2, pp. 290–299, 2021, doi: 10.32520/stmsi.v10i2.1200.
- [2] G. Mandar, A. H. Muhammad, Santosa, and Salsabila, "Klasifikasi Kualitas Kopra Menggunakan Nearest Mean Classifier Berdasarkan Warna Dan Tekstur Local Binary Pattern," *IJIS- Indones. J. Inf. Syst.*, vol. 8, no. 2, p. 164, 2023, doi: 10.36549/ijis.v8i2.251.
- [3] F. N. Raziin and R. A. Fadlillah, "Penerapan Kecerdasan Artifisial Untuk Prediksi Waktu Panen dan Kematangan Buah Jambu Kristal," in *SENTIMETER (Seminar Nasional Teknologi Informasi, Mekatronika dan Ilmu Komputer)*, Universitas Nusa Putra, 2026, pp. 263–276.
- [4] C. W. Nugroho, I. Nurtanio, and A. Jalil, "Penentuan Kualitas Kopra Berbasis Citra Kontur Menggunakan Metode Canny Edge Detection," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 1, pp. 436–450, 2025, doi: 10.57152/malcom.v5i1.1823.
- [5] L. K. O. Husni Teja Sukmana, Puspitasari, Aryajaya Alamsyah, Saepul Aripriyanto, "IMPROVING PERFORMANCE OF COPRA TYPE CLASSIFICATION USING FEATURE EXTRACTION WITH K-NEAREST NEIGHBOUR ALGORITHM," *Int. J. Ebus. eGOVERNMENT Stud.*, vol. 15, no. 1, pp. 512–532, 2023, doi: 10.34111/ijebeq.2023150123.
- [6] I. H. Lahay, "Penentuan Grade Kopra Dengan Penerapan Metode Logika Fuzzy," *Jambura J. Electr. Electron. Eng.*, vol. 5, pp. 122–129, 2023, doi: 10.37905/jjee.v5i1.17073.
- [7] N. Hayati, "Klasifikasi Jenis Bunga Mawar Menggunakan Algoritma K-Nearest Neighbour," *J. Inform. dan Ris.*, vol. 1, no. 1, pp. 31–37, 2023, doi: 10.36308/iris.v1i1.474.
- [8] T. Y. Purnomo, F. Yanto, F. Insani, and S. Ramadhani, "Penerapan Algoritma Random Forest pada Klasifikasi Daging," *J. Intra Tech*, vol. 6, no. 1, pp. 22–34, 2022, doi: doi.org/10.37030/jit.v6i1.107.
- [9] G. B. Waluyo, Y. A. Sari, and B. Rahayudi, "Pengenalan Citra Makanan Kue Tradisional menggunakan Ekstraksi Fitur HSV Color Moment dan Local Binary Pattern dengan K-Nearest Neighbour," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 12, pp. 5641–5649, 2021.
- [10] E. Santoso, F., & Hartati, "Penggunaan Algoritma Random Forest Dalam Klasifikasi Buah Segar dan Busuk," *J. Algoritma.*, vol. 3, no. 1, pp. 133–140, 2022, doi: doi.org/10.35957/algoritme.v3i1.3404.
- [11] A. S. Puspaningrum and A. A. Aldino, "Perbandingan Hasil Klasifikasi Jenis Daging Menggunakan Ekstraksi Ciri Tekstur Gray Level Co-occurrence Matrices (GLCM) dan Local Binary Pattern (LBP)," *SMATIKA J. STIKI Inform. J.*, vol. 11, no. 01, pp. 48–52,

- 2021, doi: doi.org/10.32664/smatika.v11i01.572.
- [12] E. Hartati, “Penggunaan Klasifikasi Sayur Segar dan Sayur Busuk Menggunakan Algoritma Support Vector Machine,” *J. Tek. Inform. dan Sist. Inf.*, vol. 7, no. 3, pp. 678–687, 2020, doi: 10.35957/jatisi.v7i3.3160.
- [13] N. S. Fatimah and S. Agustin, “Klasifikasi Citra Batik Menggunakan Local Binary Pattern (LBP) dan Support Vector Machine (SVM),” *J. Algoritma.*, vol. 22, no. 1, pp. 185–196, 2025, doi: 10.33364/algoritma/v.22-1.2208.
- [14] S. Adiningsi, B. Pramono, A. M. Sajiah, and R. A. Saputra, “Identifikasi Kualitas Ikan Cakalang Segar Berbasis Citra Mata Menggunakan Metode Support Vector Machine (SVM) Dengan Fungsi Kernel Radial Basis Function,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 1, pp. 1522–1530, 2025.
- [15] A. Hamzah, E. Susanti, and R. M. Lestari, “Klasifikasi Kematangan Buah Alpukat Mentega Berdasarkan Fitur Warna Menggunakan Support Vector Machine (SVM),” *J. Innov. Futur. Technol.*, vol. 6, no. 1, pp. 108–120, 2024, doi: 10.47080/itech.v2i2.1025.
- [16] M. Mellyadi and P. Harliana, “Segmentasi Citra Satelit dalam Observasi dan Konservasi Hutan Lindung Taman Nasional Gunung Lauser Menggunakan Algoritma Fuzzy C-Means,” *HELLO WORLD J. ILMU Komput.*, vol. 1, no. 2, pp. 90–96, 2022, doi: 10.56211/helloworld.v1i2.44.
- [17] S. Ayu, R. Srg, M. F. Aldi, and M. Ramadhan, “Ekstraksi Fitur Citra Berdasarkan Tekstur dengan GLCM (Gray Level Co-Occurrence),” *JUTISAL (Jurnal Tek. Inform. Komput. Universal)*, vol. 3, no. 1, pp. 44–51, 2023.
- [18] A. I. R. F. Alqob, F. Badri, and O. Melfazen, “Model Klasifikasi Karies Gigi Pada Citra Gigi Berbasis Local Binary Pattern (LBP) dengan Menggunakan Convolutional Neural Network (CNN),” *J. MEDIA Akad.*, vol. 4, no. 1, pp. 1–16, 2026, doi: 10.62281/gzq06690.
- [19] R. A. M. Mutmainnah Muchtar, “Perbandingan Metode KNN dan SVM dalam Klasifikasi Kematangan Buah Mangga Berdasarkan Citra Hsv Dan Fitur Statistik,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.*, vol. 12, no. 2, pp. 167–186, 2021, doi: doi.org/10.23960/jitet.v12i2.4010.
- [20] U. Maulidia, F. Wajidi, and N. Arifin, “Klasifikasi Penyakit Pada Daun Tanaman Kubis Menggunakan Metode Support Vector Machine (SVM),” *Techno.COM*, vol. 24, no. 3, pp. 1053–1066, 2025, doi: 10.62411/tc.v24i3.13748.
- [21] C. C. V. Vapnik, “Support-Vector Networks,” *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.