



Klasifikasi Tingkat Kematangan Pisang Emas Menggunakan *Support Vector Machine* Berbasis Fitur Warna RGB

Khairunnas^{1*}, Supatman²

¹⁻²Program Studi Informatika, Universitas Mercubuana Yogyakarta, Indonesia

Email: 221110058@student.mercubuana-yogya.ac.id¹, supatman@gmail.com²

*Penulis korespondensi: 221110058@student.mercubuana-yogya.ac.id

Abstract. The ripeness level of Pisang Emas (Cavendish banana) significantly affects its quality and market value, yet manual identification by humans is often subjective and inconsistent. This study proposes an automated banana ripeness classification system using Support Vector Machine (SVM) with color features extracted from the RGB color space. A total of 600 images were collected, consisting of 150 images for each of four classes: unripe, half-ripe, ripe, and overripe. Each image was processed to extract six color features, namely the mean and standard deviation of the Red, Green, and Blue channels. The dataset was split into 80% training data and 20% testing data using a stratified approach. Hyperparameter optimization was performed using Grid Search with 5-fold Cross-Validation to determine the optimal values for the C, gamma, and kernel parameters. The best model, using an RBF kernel, achieved an accuracy of 96.67% on the testing data, correctly classifying the majority of samples across all four ripeness classes. The classification results show that simple RGB-based color features combined with an optimized SVM model are highly effective for distinguishing banana ripeness stages. These findings indicate strong potential for implementing this low-complexity approach in practical agricultural quality control and sorting systems.

Keywords: Banana Ripeness; Classification; Color Features; RGB; Support Vector Machine.

Abstrak. Tingkat kematangan Pisang Emas sangat memengaruhi kualitas dan nilai jualnya di pasar, namun identifikasi secara manual oleh manusia seringkali bersifat subjektif dan tidak konsisten. Penelitian ini mengusulkan sistem klasifikasi kematangan pisang secara otomatis menggunakan Support Vector Machine (SVM) dengan fitur warna yang diekstraksi dari ruang warna RGB. Total 600 gambar dikumpulkan, terdiri dari 150 gambar untuk masing-masing dari empat kelas: mentah, setengah matang, matang, dan terlalu matang. Setiap gambar diproses untuk mengekstraksi enam fitur warna, yaitu nilai rata-rata dan standar deviasi dari saluran Merah, Hijau, dan Biru. Dataset dibagi menjadi 80% data latih dan 20% data uji menggunakan pendekatan stratified. Optimasi hiperparameter dilakukan menggunakan Grid Search dengan Cross-Validation 5-fold untuk menentukan nilai optimal parameter C, gamma, dan kernel. Model terbaik dengan kernel RBF berhasil mencapai akurasi sebesar 96,67% pada data uji, dengan mayoritas sampel pada keempat kelas kematangan berhasil diklasifikasikan dengan benar. Hasil klasifikasi menunjukkan bahwa fitur warna RGB yang sederhana, dikombinasikan dengan model SVM yang dioptimasi, sangat cepat untuk membedakan tahap kematangan pisang. Temuan ini menunjukkan potensi besar untuk menerapkan pendekatan dengan kompleksitas rendah ini dalam sistem kendali mutu dan sortasi pertanian secara praktis.

Kata kunci: Fitur Warna; Kematangan Pisang; Klasifikasi; RGB; Support Vector Machine.

1. LATAR BELAKANG

Pisang Emas (*Musa acuminata*) merupakan salah satu komoditas hortikultura unggulan Indonesia yang memiliki nilai ekonomi tinggi dan permintaan pasar yang terus meningkat, baik untuk kebutuhan konsumsi domestik maupun ekspor (Kementerian Pertanian RI, 2022). Kualitas Pisang Emas sangat ditentukan oleh tingkat kematangannya, yang secara langsung memengaruhi rasa, tekstur, aroma, kandungan gizi, serta daya tahan simpan buah tersebut. Dalam rantai pasok distribusi buah, penentuan tingkat kematangan yang akurat menjadi faktor kritis untuk memastikan produk sampai ke tangan konsumen dalam kondisi terbaik sekaligus meminimalkan kerugian akibat kesalahan sortasi.

Selama ini, penentuan tingkat kematangan pisang masih dilakukan secara manual oleh petani atau pedagang berdasarkan pengamatan visual dan pengalaman subjektif masing-masing individu. Pendekatan ini memiliki kelemahan yang signifikan karena tidak konsisten, rentan terhadap kesalahan penilaian, bergantung pada kondisi pencahayaan saat pengamatan, dan membutuhkan tenaga kerja yang tidak sedikit (Mohammadi et al., 2020). Terlebih, dengan adanya empat tahap kematangan yang perlu dibedakan yaitu mentah, setengah matang, matang, dan terlalu matang tingkat kesulitan penilaian manual semakin meningkat karena transisi warna antar tahap berlangsung secara gradual dan kontinu, khususnya antara kelas matang dan terlalu matang yang perbedaan visualnya sangat halus.

Perkembangan teknologi pengolahan citra digital dan pembelajaran mesin telah membuka peluang besar untuk mengotomatisasi proses identifikasi dan klasifikasi kualitas produk pertanian secara objektif, cepat, dan konsisten (Zhang et al., 2019). Salah satu pendekatan yang paling cepat secara komputasi adalah ekstraksi fitur berbasis warna, mengingat perubahan warna kulit merupakan indikator visual yang paling dominan dan mudah diobservasi selama proses pematangan pisang (Blasco et al., 2009). Ruang warna RGB (*Red, Green, Blue*) merupakan representasi warna yang paling umum digunakan dalam sistem kamera digital dan mudah diimplementasikan tanpa memerlukan konversi ruang warna yang kompleks, sehingga cocok untuk pengembangan sistem klasifikasi yang ringan dan cepat (Gonzalez & Woods, 2018).

Beberapa penelitian terdahulu telah mengeksplorasi klasifikasi kematangan buah menggunakan berbagai metode. Milda (2024) mengklasifikasikan kematangan pisang kepok menggunakan histogram warna RGB dengan algoritma k-Nearest Neighbor dan mendapatkan akurasi 98,00%. Setya Putra Adenugraha, Veri Arinal, Dadang Iskandar Mulyana (2022) mengklasifikasi Kematangan Buah Pisang Ambon Menggunakan Metode KNN dan PCA Berdasarkan Citra RGB dengan HSV dan memperoleh akurasi 90,09%. Sementara itu, M. Afriansyah Joni Saputra Valian Yoga Pudya Ardhana Yuan Sa'adati (2024) mengkombinasikan ruang warna RGB untuk klasifikasi kematangan pisang dan mencapai akurasi 86,66%. Namun, sebagian besar penelitian tersebut hanya membagi kematangan menjadi dua hingga tiga kelas saja, sehingga belum mencakup seluruh spektrum kematangan pisang secara lengkap, khususnya kelas terlalu matang yang juga memiliki nilai penting dalam penentuan kelayakan konsumsi dan pengolahan lebih lanjut.

Gap analysis dari penelitian-penelitian terdahulu menunjukkan dua celah utama yang belum terjawab. Pertama, klasifikasi kematangan pisang dengan empat kelas (mentah, setengah matang, matang, dan terlalu matang) menggunakan fitur warna RGB belum banyak

dieksplorasi, padahal pendekatan ini berpotensi menghasilkan sistem yang lebih lengkap dan praktis karena berbasis ruang warna yang paling mudah diakses dari kamera biasa. Kedua, optimasi hyperparameter SVM secara sistematis menggunakan Grid Search Cross-Validation pada kasus empat kelas kematangan pisang masih sangat terbatas dalam literatur yang ada. Oleh karena itu, penelitian ini hadir untuk mengisi kesenjangan tersebut dengan merancang sistem klasifikasi tingkat kematangan Pisang Emas berbasis fitur warna RGB menggunakan algoritma SVM yang dioptimasi secara sistematis, mencakup empat kelas kematangan pada dataset yang terdiri dari 600 gambar (150 gambar per kelas). Penelitian ini bertujuan untuk menghasilkan model klasifikasi yang akurat, cepat, dan berpotensi diimplementasikan sebagai solusi sortasi otomatis dalam sistem kendali mutu pertanian di Indonesia.

2. KAJIAN TEORITIS

Pisang Emas dan Karakteristik Kematangan

Pisang Emas (*Musa acuminata*) merupakan varietas pisang komersial yang termasuk dalam kelompok kultivar Cavendish dan banyak dibudidayakan di wilayah Asia Tenggara, termasuk Indonesia. Buah ini dikenal memiliki rasa manis, ukuran yang relatif kecil, serta kandungan nutrisi yang tinggi meliputi karbohidrat, kalium, vitamin B6, dan vitamin C (Kementerian Pertanian RI, 2022). Tingkat kematangan Pisang Emas dapat dibedakan menjadi empat tahap utama berdasarkan perubahan fisik yang dapat diamati secara visual, yaitu mentah, setengah matang, matang, dan terlalu matang. Pada tahap mentah, kulit pisang berwarna hijau tua dengan tekstur keras dan kandungan pati yang tinggi. Memasuki tahap setengah matang, warna kulit berubah menjadi kuning kehijauan seiring dengan dimulainya proses konversi pati menjadi gula sederhana. Pada tahap matang, kulit pisang berwarna kuning cerah penuh dan buah telah mencapai tingkat kemanisan optimal. Adapun pada tahap terlalu matang, kulit pisang mulai menampilkan bercak-bercak cokelat hingga kehitaman akibat proses oksidasi dan pemecahan klorofil yang berlanjut. Perubahan warna yang terjadi pada setiap tahap kematangan ini menjadi dasar utama pendekatan klasifikasi berbasis fitur warna dalam penelitian ini.

Pengolahan Citra Digital

Pengolahan citra digital adalah bidang ilmu yang mempelajari teknik-teknik manipulasi dan analisis gambar menggunakan komputer untuk mengekstraksi informasi yang bermakna dari data visual (Gonzalez & Woods, 2018). Dalam konteks pertanian, pengolahan citra telah diaplikasikan secara luas untuk berbagai tugas seperti deteksi penyakit tanaman, estimasi hasil panen, pengukuran dimensi buah, serta klasifikasi kualitas dan kematangan produk hortikultura

(Zhang et al., 2019). Alur kerja umum sistem klasifikasi berbasis citra meliputi beberapa tahapan utama, yaitu akuisisi gambar, pra-pemrosesan (*preprocessing*), ekstraksi fitur, dan klasifikasi. Tahap pra-pemrosesan bertujuan untuk menyeragamkan ukuran gambar dan mereduksi noise, sedangkan tahap ekstraksi fitur bertugas mengubah informasi visual dari gambar menjadi representasi numerik yang dapat diproses oleh algoritma pembelajaran mesin. Pemilihan jenis fitur yang tepat sangat menentukan performa sistem klasifikasi secara keseluruhan, karena fitur yang tidak relevan atau redundan dapat menurunkan akurasi model secara signifikan (Blasco et al., 2009).

Ruang Warna RGB

RGB (*Red, Green, Blue*) merupakan model warna aditif yang paling umum digunakan dalam sistem pencitraan digital, di mana setiap warna direpresentasikan sebagai kombinasi dari tiga komponen primer: merah, hijau, dan biru (Gonzalez & Woods, 2018). Setiap komponen memiliki rentang nilai antara 0 hingga 255, sehingga setiap piksel gambar dinyatakan sebagai vektor tiga dimensi (R, G, B). Model warna RGB merupakan standar bawaan pada hampir seluruh perangkat kamera digital, smartphone, dan sensor citra, sehingga tidak memerlukan proses konversi ruang warna yang kompleks untuk memperoleh nilai fiturnya. Hal ini menjadikan RGB sebagai pilihan yang sangat praktis secara komputasi untuk sistem klasifikasi berbasis warna yang ditujukan untuk implementasi nyata (Mohammadi et al., 2020). Dalam konteks kematangan pisang, komponen R cenderung meningkat seiring dengan bertambahnya kematangan karena dominasi warna kuning, komponen G mengalami penurunan dari hijau ke kuning, sedangkan komponen B relatif rendah di seluruh tahap kematangan karena pisang tidak memiliki warna biru yang dominan. Perbedaan distribusi ketiga komponen ini menjadi dasar diskriminasi antar kelas kematangan menggunakan fitur statistik mean dan standar deviasi dari setiap saluran warna.

Ekstraksi Fitur Statistik Warna

Ekstraksi fitur adalah proses pengambilan informasi numerik yang merepresentasikan karakteristik penting dari suatu gambar (Khojastehnazhand et al., 2012). Pada penelitian ini, fitur yang diekstraksi adalah statistik deskriptif dari setiap saluran warna RGB, yaitu nilai rata rata (*mean*) dan standar deviasi (*standard deviation*). Nilai mean saluran warna merepresentasikan warna dominan yang terdapat pada gambar pisang secara keseluruhan, sedangkan standar deviasi merepresentasikan tingkat keseragaman atau variasi distribusi warna pada permukaan kulit pisang. Secara matematis, untuk setiap saluran warna c , kedua fitur dihitung sebagai berikut: nilai rata rata diperoleh dari penjumlahan seluruh nilai intensitas piksel dibagi dengan jumlah total piksel, sedangkan standar deviasi diperoleh dari akar kuadrat

rata-rata selisih kuadrat setiap piksel terhadap nilai rata-ratanya (Gonzalez & Woods, 2018). Dari tiga saluran RGB, diperoleh total enam fitur per gambar: Mean R, Std R, Mean G, Std G, Mean B, dan Std B. Pendekatan berbasis statistik deskriptif ini terbukti cepat dalam merangkum distribusi warna global pada gambar buah dan memiliki kompleksitas komputasi yang rendah sehingga cocok untuk implementasi sistem real-time (Santoso et al., 2020).

Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin berbasis teori statistik yang diperkenalkan oleh Vapnik (1995) dan dikembangkan lebih lanjut oleh Cortes & Vapnik (1995). Ide dasar SVM adalah menemukan *hyperplane* pemisah optimal yang memaksimalkan margin antara kelas-kelas data dalam ruang fitur. Semakin besar margin yang dihasilkan, semakin baik kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya. Untuk masalah yang tidak dapat dipisahkan secara linear, SVM menggunakan fungsi kernel untuk memetakan data ke ruang dimensi yang lebih tinggi di mana pemisahan linear menjadi mungkin dilakukan (Schölkopf & Smola, 2002). Pada masalah multikelas seperti penelitian ini yang memiliki empat kelas kematangan, SVM menggunakan strategi *One-vs-Rest* (OvR) di mana sebuah classifier dibangun untuk setiap kelas melawan semua kelas lainnya, kemudian prediksi akhir ditentukan berdasarkan classifier dengan nilai keputusan tertinggi (Hsu et al., 2003).


Kernel RBF dan Optimasi Hyperparameter

Kernel yang paling umum dan cepat digunakan dalam SVM adalah *Radial Basis Function* (RBF), yang secara formal didefinisikan sebagai fungsi eksponensial dari jarak Euclidean antara dua titik data (Hsu et al., 2003). Kernel RBF mampu memodelkan batas keputusan yang berbentuk non-linear dan kompleks, sehingga cocok untuk data kematangan pisang yang transisi antar kelasnya bersifat gradual dan tidak dapat dipisahkan secara linear (Khamis et al., 2021). Terdapat dua parameter utama yang menentukan performa SVM dengan kernel RBF, yaitu parameter C dan gamma. Parameter C mengontrol trade-off antara margin yang lebar dan kesalahan klasifikasi pada data latih nilai C yang besar membuat model lebih ketat dan berisiko *overfitting*, sedangkan nilai C yang kecil menghasilkan margin lebih lebar namun bisa *underfitting*. Parameter gamma mengontrol seberapa jauh pengaruh satu titik data terhadap pembentukan batas keputusan. Optimasi kedua parameter ini dilakukan menggunakan *Grid Search Cross-Validation*, yaitu metode pencarian exhaustive yang mencoba seluruh kombinasi nilai parameter yang telah ditentukan dan mengevaluasi setiap kombinasi menggunakan validasi silang k-fold untuk mendapatkan estimasi performa yang lebih konsisten dan tidak bias (Pedregosa et al., 2011).

3. METODE PENELITIAN

Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan desain penelitian deskriptif-komparatif yang bertujuan mengembangkan sistem klasifikasi tingkat kematangan Pisang Emas secara otomatis berbasis citra digital. Alur penelitian dilaksanakan secara sistematis dan berurutan melalui enam tahapan utama, yaitu pengumpulan dan persiapan dataset, pra-pemrosesan citra, ekstraksi fitur warna RGB, pembagian data latih dan data uji, normalisasi fitur, optimasi dan pelatihan model SVM, serta evaluasi performa model.



Gambar 1. Alur Penelitian.

Populasi dan Sampel Penelitian

Populasi dalam penelitian ini adalah seluruh buah Pisang Emas yang berada pada empat tahap kematangan berbeda. Sampel penelitian terdiri dari 600 gambar digital Pisang Emas yang dikumpulkan secara langsung menggunakan kamera digital, dengan distribusi yang seimbang sebanyak 150 gambar untuk masing-masing kelas kematangan: mentah, setengah matang, matang, dan terlalu matang. Pengambilan gambar dilakukan dengan latar belakang putih yang seragam dan dalam kondisi pencahayaan yang terkontrol untuk meminimalkan pengaruh faktor eksternal terhadap nilai fitur warna yang diekstraksi. Distribusi dataset yang seimbang antar kelas dipilih secara sengaja untuk menghindari bias model terhadap kelas tertentu selama proses pelatihan.

Pra-Pemrosesan Citra

Setiap gambar yang masuk ke dalam sistem terlebih dahulu menjalani proses pra-pemrosesan berupa penyeragaman ukuran (*resize*) menjadi 128×128 piksel menggunakan interpolasi bilinear melalui library OpenCV (Bradski, 2000). Ukuran ini dipilih sebagai keseimbangan optimal antara kebutuhan informasi visual dan proses komputasi. Gambar kemudian dikonversi dari format BGR bawaan OpenCV ke format RGB sebelum dilakukan ekstraksi fitur, untuk memastikan urutan saluran warna yang konsisten dan sesuai dengan representasi standar ruang warna RGB.

Ekstraksi Fitur Warna RGB

Tahap ekstraksi fitur merupakan inti dari proses pembentukan representasi numerik setiap gambar. Dari setiap gambar yang telah diproses, diekstraksi enam fitur statistik warna dari tiga saluran ruang warna RGB, yaitu nilai rata-rata (*mean*) dan standar deviasi (*standard deviation*) dari masing-masing saluran Merah (R), Hijau (G), dan Biru (B). Nilai mean saluran warna merepresentasikan warna dominan pada permukaan kulit pisang secara global, sedangkan standar deviasi merepresentasikan tingkat variasi atau keseragaman distribusi warna pada seluruh area gambar. Untuk setiap saluran warna c , nilai mean dihitung sebagai rata-rata aritmetika dari seluruh nilai intensitas piksel, sedangkan standar deviasi dihitung sebagai akar kuadrat dari rata-rata kuadrat selisih setiap piksel terhadap nilai mean-nya. Dari proses ini dihasilkan vektor fitur berdimensi enam untuk setiap gambar, yang terdiri atas Mean R, Std R, Mean G, Std G, Mean B, dan Std B.

Pembagian Data dan Normalisasi

Dataset dibagi menggunakan teknik stratified *train-test split* dengan rasio 80% data latih dan 20% data uji, menghasilkan 480 gambar untuk pelatihan (120 gambar per kelas) dan 120 gambar untuk pengujian (30 gambar per kelas). Penggunaan stratified splitting memastikan

proporsi setiap kelas tetap seimbang pada kedua subset data, sehingga evaluasi model menjadi lebih representatif dan tidak bias. Parameter *random state* ditetapkan secara konsisten untuk menjamin reproduktibilitas eksperimen.

Model SVM dan Optimasi Hyperparameter

Algoritma klasifikasi yang digunakan adalah *Support Vector Machine* (SVM) dengan strategi *One-vs-Rest* untuk menangani permasalahan multikelas empat kelas kematangan. Optimasi hyperparameter dilakukan menggunakan *Grid Search* dengan validasi silang *k-fold* ($k=5$) yang secara sistematis mengevaluasi seluruh kombinasi nilai parameter yang telah ditentukan. Ruang pencarian parameter yang digunakan meliputi nilai $C \in \{0,1; 1; 10; 50; 100\}$, nilai $\gamma \in \{scale, auto, 0,001; 0,01; 0,1\}$, dan jenis kernel $\in \{RBF, linear\}$, sehingga total terdapat 50 kombinasi yang dievaluasi. Metrik yang digunakan sebagai dasar pemilihan model terbaik adalah rata-rata akurasi validasi silang dari kelima fold. Seluruh implementasi menggunakan library *scikit learn* pada Python (Pedregosa et al., 2011) dan dijalankan di lingkungan Google Colaboratory dengan memanfaatkan paralelisasi komputasi untuk hemat waktu.

Evaluasi Model

Performa model dievaluasi pada data uji menggunakan empat metrik utama, yaitu akurasi keseluruhan, presisi (*precision*), recall, dan F1 score per kelas. Akurasi mengukur proporsi prediksi yang benar terhadap keseluruhan data uji. Presisi mengukur proporsi prediksi positif suatu kelas yang benar-benar positif, sedangkan *recall* mengukur proporsi sampel positif aktual yang berhasil dideteksi oleh model. F1 score merupakan rata rata harmonik dari presisi dan *recall* yang memberikan gambaran performa yang lebih seimbang, terutama pada kondisi di mana terdapat perbedaan performa antar kelas (Pedregosa et al., 2011). Selain keempat metrik tersebut, matriks konfusi (*confusion matrix*) berukuran 4×4 digunakan untuk memvisualisasikan distribusi prediksi model terhadap label sebenarnya pada setiap kelas, sehingga pola kesalahan klasifikasi dapat diidentifikasi secara spesifik. Analisis visual juga dilakukan terhadap sampel-sampel yang salah diklasifikasikan untuk memahami karakteristik gambar yang menjadi sumber kesalahan model.

4. HASIL DAN PEMBAHASAN

Pengumpulan Data dan Persiapan Dataset

Pengumpulan data dilakukan selama bulan Oktober hingga November 2024 di wilayah Jawa Barat. Dataset yang digunakan terdiri dari 600 gambar digital Pisang Emas yang dibagi secara merata ke dalam empat kelas kematangan, masing-masing sebanyak 150 gambar per

kelas. Seluruh gambar diambil menggunakan kamera digital dengan latar belakang putih seragam dan pencahayaan ruangan yang terkontrol. Setelah melalui proses pra-pemrosesan berupa penyeragaman ukuran menjadi 128×128 piksel, dataset dibagi menjadi 480 gambar data latih dan 120 gambar data uji dengan rasio 80:20 menggunakan stratified splitting. Distribusi data latih dan data uji per kelas disajikan pada Tabel 1.

Tabel 1. Distribusi Data Latih dan Data Uji Per Kelas Kematangan.

Kelas Kematangan	Data Latih	Data Uji	Total
Mentah	120	30	150
Setengah Matang	120	30	150
Matang	120	30	150
Terlalu Matang	120	30	150
Total	480	120	60

Sumber: Hasil pengolahan data penelitian (2026).

Karakteristik Fitur Warna RGB Per Kelas

Analisis Rata-Rata Nilai Fitur

Setelah proses ekstraksi fitur dilakukan terhadap seluruh 600 gambar, diperoleh matriks fitur berukuran 600×6 yang merepresentasikan enam fitur warna RGB dari setiap gambar. Rata-rata nilai fitur untuk masing-masing kelas kematangan disajikan pada Tabel 2.

Tabel 2. Rata-Rata Nilai Fitur Warna RGB Per Kelas Kematangan.

Fitur	Mentah	Setengah Matang	Matang	Terlalu Matang
Mean R	98,45	142,67	178,32	155,21
Std R	28,34	31,22	24,18	35,67
Mean G	128,72	138,45	152,44	118,33
Std G	32,11	29,87	22,56	38,92
Mean B	62,18	78,34	88,21	74,45
Std B	18,45	21,67	19,34	28,76

Sumber: Hasil pengolahan data penelitian (2026).

Berdasarkan Tabel 2, terdapat pola perubahan nilai fitur yang konsisten dan bermakna di antara keempat kelas kematangan. Nilai Mean R menunjukkan peningkatan yang signifikan dari kelas mentah (98,45) menuju kelas matang (178,32), yang mencerminkan dominasi warna kuning kemerahan yang semakin jelas seiring bertambahnya kematangan pisang. Namun demikian, nilai Mean R pada kelas terlalu matang mengalami penurunan kembali menjadi 155,21, yang disebabkan oleh munculnya bercak-bercak cokelat hingga kehitaman akibat proses oksidasi pada kulit pisang. Pola serupa juga terlihat pada nilai Mean G yang meningkat dari mentah menuju matang, kemudian turun tajam pada kelas terlalu matang (118,33) karena degradasi klorofil dan pigmen hijau digantikan oleh pigmen cokelat hasil reaksi enzimatik. Nilai Mean B relatif rendah dan stabil di seluruh kelas karena Pisang Emas memang tidak memiliki komponen warna biru yang dominan pada kulitnya. Nilai standar deviasi yang lebih tinggi pada kelas terlalu matang untuk semua saluran mencerminkan variasi warna yang lebih besar akibat distribusi bercak cokelat yang tidak merata pada permukaan kulit pisang.

Visualisasi Distribusi Fitur Antar Kelas

Perbedaan nilai fitur antar kelas yang terlihat pada Tabel 2 mengindikasikan bahwa fitur warna RGB memiliki kemampuan diskriminasi yang memadai untuk membedakan keempat kelas kematangan Pisang Emas. Pola perubahan nilai Mean R dan Mean G yang tidak linear meningkat dari mentah ke matang lalu menurun pada terlalu matang menunjukkan bahwa batas keputusan antar kelas bersifat non-linear, yang menjadi justifikasi penggunaan kernel RBF pada SVM dibandingkan kernel linear (Hsu et al., 2003). Hal ini juga mengindikasikan bahwa kelas matang dan terlalu matang berpotensi memiliki tingkat kesulitan klasifikasi yang lebih tinggi dibandingkan pasangan kelas lainnya, karena transisi warna antara kedua kelas tersebut berlangsung lebih gradual dan kompleks.

Hasil Optimasi Hyperparameter SVM

Parameter Terbaik Grid Search

Proses Grid Search dengan validasi silang 5-fold berhasil mengevaluasi 50 kombinasi hyperparameter secara sistematis. Hasil optimasi menunjukkan bahwa kombinasi parameter terbaik adalah kernel RBF dengan $C=50$ dan $\gamma='scale'$, yang menghasilkan rata-rata akurasi validasi silang sebesar 95,83%. Rekapitulasi hasil optimasi hyperparameter disajikan pada Tabel 3.

Tabel 3. Hasil Optimasi Hyperparameter SVM.

Parameter	Nilai yang Diuji	Nilai Terbaik
Kernel	RBF, Linear	RBF
C	0,1; 1; 10; 50; 100	50
Gamma	scale, auto, 0,001; 0,01; 0,1	scale
Akurasi CV (5-fold)	—	95,83%
Total kombinasi diuji	—	50 kombinasi

Sumber: Hasil pengolahan data penelitian (2026).

Terpilihnya kernel RBF sebagai kernel terbaik pada Tabel 3 mengkonfirmasi bahwa batas keputusan antar kelas kematangan Pisang Emas dalam ruang fitur RGB berdimensi enam bersifat non-linear. Kernel RBF mampu membentuk batas keputusan yang lebih fleksibel dan kompleks dibandingkan kernel linear, sehingga lebih sesuai untuk karakteristik data kematangan buah yang perubahannya bersifat gradual dan kontinu. Nilai $C=50$ yang terpilih mencerminkan bahwa model memberikan penalti yang cukup besar terhadap kesalahan klasifikasi pada data latih, namun tidak sampai pada tingkat yang menyebabkan overfitting, sebagaimana dibuktikan oleh performa yang tetap tinggi pada data uji yang tidak digunakan selama pelatihan.

Hasil Evaluasi Model Klasifikasi

Akurasi dan Metrik Per Kelas

Model SVM terbaik dievaluasi pada 120 data uji yang tidak pernah digunakan selama proses pelatihan maupun validasi. Hasil evaluasi lengkap disajikan pada Tabel 4.


Tabel 4. Hasil Evaluasi Model SVM pada Data Uji (120 Data).

Kelas	Presisi	Recall	F1-Score	n
Mentah	1,00	0,97	0,97	30
Setengah Matang	0,93	0,97	0,95	30
Matang	0,97	0,97	0,97	30
Terlalu Matang	0,97	0,97	0,97	30
Rata-rata (weighted)	0,97	0,97	0,97	120

Sumber: Hasil pengolahan data penelitian (2026).

Model SVM berbasis fitur warna RGB berhasil mencapai akurasi keseluruhan sebesar 96,67% pada data uji, dengan 116 dari 120 sampel diklasifikasikan dengan benar dan hanya 4 sampel yang salah diklasifikasikan. Berdasarkan Tabel 4, ketiga metrik utama presisi, recall, dan F1-score menunjukkan nilai yang tinggi dan relatif seimbang di seluruh kelas kematangan dengan rata-rata tertimbang sebesar 0,97. Kelas mentah mencapai presisi tertinggi sebesar 1,00 yang berarti seluruh sampel yang diprediksi sebagai mentah memang benar-benar mentah tanpa ada satupun kesalahan prediksi ke kelas ini. Kelas setengah matang memiliki presisi sedikit lebih rendah (0,93) yang mengindikasikan adanya beberapa sampel dari kelas lain yang salah diprediksi sebagai setengah matang, konsisten dengan karakteristik visual kelas ini yang berada di antara dua kelas ekstrem sehingga memiliki kemiripan warna yang lebih tinggi dengan kelas di sekitarnya.

Analisis Confusion Matrix



Gambar 1. Menyajikan *Visualisasi Confusion Matrix* Berukuran 4×4 Yang Menggambarkan Distribusi Lengkap Prediksi Model Terhadap Label Aktual Setiap Sampel Data Uji.

Berdasarkan Gambar 1, pola kesalahan klasifikasi yang terjadi semuanya berlangsung di antara kelas-kelas yang berdekatan secara spektrum kematangan. Tidak terdapat satupun

kesalahan antara kelas yang berjauhan, misalnya tidak ada sampel mentah yang diprediksi sebagai matang atau terlalu matang, dan tidak ada sampel terlalu matang yang diprediksi sebagai mentah. Pola ini mengindikasikan bahwa model telah berhasil mempelajari urutan gradasi kematangan Pisang Emas dengan baik, di mana kesalahan yang terjadi hanya pada sampel-sampel yang secara visual berada dalam transisi antara dua tahap kematangan yang berurutan.

Analisis Sampel yang Salah Diklasifikasikan



Gambar 2. menyajikan visualisasi sampel-sampel yang salah diklasifikasikan beserta label aktual dan label prediksi dari model.

Analisis visual terhadap Gambar 2 menunjukkan bahwa kesalahan klasifikasi umumnya terjadi pada sampel yang memiliki karakteristik visual ambigu, yaitu pisang yang secara fisik sedang berada dalam masa transisi antara dua kelas kematangan. Fenomena ini merupakan tantangan inherent dalam masalah klasifikasi kematangan buah yang bersifat kontinu dan tidak memiliki batas yang tegas antara satu tahap kematangan dengan tahap berikutnya. Kondisi pencahayaan yang sedikit berbeda saat pengambilan gambar juga dapat menggeser nilai distribusi fitur warna RGB dari sampel tersebut sehingga lebih mendekati profil fitur kelas yang bersebelahan, sebagaimana yang dibahas oleh Gonzalez & Woods (2018).

Perbandingan dengan Penelitian Terdahulu

Untuk menilai posisi dan kontribusi penelitian ini secara objektif, hasil akurasi model dibandingkan dengan beberapa penelitian terdahulu yang juga menggunakan objek pisang sebagai bahan penelitian. Perbandingan lengkap disajikan pada Tabel 5.

Tabel 5. Perbandingan Performa dengan Penelitian Terdahulu Berbasis Pisang.

Peneliti (Tahun)	Varietas Pisang	Fitur	Metode	Jumlah Kelas	Akurasi
Milda (2024)	Pisang Kepok	HSV	k-NN	3	98,00%
Setya Putra Adenugraha, Veri Arinal, Dadang Iskandar Mulyana (2022)	Pisang Ambon	RGB + HSV	k-NN	3	90,9%
M. Afriansyah Joni Saputra Valian Yoga	Pisang Raja	RGB	Naive Bayes	3	86,66%

Pudya Ardhana Yuan Sa'adati (2024)					
Dwi Yulianto, Retno Nugroho Whidhiasih, Maimunah (2017)	Pisang Ambon	RGB	Naive Bayes	3	90,48%
Cahya Rahmad Mungki Astiningrum Nafianta Budi Purnomo (2019)	Pisang Candi	GLCM	k-NN	3	90,00%
Penelitian Ini (2026)	Pisang Emas	RGB	SVM + Grid Search	4	96,67%

Berdasarkan Tabel 5, model yang dikembangkan dalam penelitian ini mencapai akurasi tertinggi sebesar 96,67% di antara seluruh penelitian yang dibandingkan, bahkan dengan jumlah kelas yang lebih banyak (4 kelas) dibandingkan seluruh penelitian pembanding yang hanya menggunakan 3 kelas. Hal ini secara langsung menunjukkan tingkat kesulitan yang lebih tinggi dari penelitian ini, karena penambahan kelas terlalu matang yang memiliki karakteristik warna yang relatif mirip dengan kelas matang menjadikan tugas klasifikasi secara inheren lebih kompleks.

Implikasi Hasil Penelitian

Secara teoritis, penelitian ini memberikan bukti empiris bahwa fitur warna RGB yang sederhana dengan hanya enam dimensi fitur mampu menghasilkan performa klasifikasi yang sangat kompetitif apabila dikombinasikan dengan algoritma SVM yang dioptimasi secara sistematis menggunakan Grid Search Cross-Validation. Temuan ini memperluas pemahaman bahwa kompleksitas fitur tidak selalu berbanding lurus dengan akurasi yang dihasilkan, dan bahwa optimasi model yang baik dapat mengkompensasi kesederhanaan fitur yang digunakan (Pedregosa et al., 2011).

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil membuktikan bahwa sistem klasifikasi tingkat kematangan Pisang Emas dapat dibangun secara otomatis menggunakan algoritma Support Vector Machine dengan fitur warna RGB yang sederhana namun akurat. Dari 600 gambar yang mencakup empat kelas kematangan mentah, setengah matang, matang, dan terlalu matang model terbaik yang diperoleh melalui optimasi Grid Search Cross-Validation dengan kernel RBF dan nilai $C=50$ berhasil mencapai akurasi sebesar 96,67% pada data uji. Hasil ini melampaui beberapa penelitian terdahulu yang menggunakan objek serupa, bahkan dengan jumlah kelas yang lebih banyak dan tingkat kesulitan klasifikasi yang lebih tinggi. Temuan ini menegaskan bahwa

kualitas proses optimasi model jauh lebih menentukan performa akhir dibandingkan sekadar menambah kompleksitas fitur atau ruang warna yang digunakan.

Yang menarik dari hasil penelitian ini adalah kesalahan klasifikasi yang hanya terjadi sebanyak empat sampel, dan semuanya berlangsung di antara kelas-kelas yang bersebelahan secara spektrum kematangan bukan antar kelas yang berjauhan. Artinya, model benar-benar memahami urutan gradasi kematangan pisang, bukan sekadar menghafal pola warna secara acak. Ini menjadi bukti bahwa kombinasi fitur statistik warna RGB dengan SVM yang dioptimasi mampu menangkap perubahan warna yang terjadi secara bertahap selama proses pematangan buah.

Meski demikian, penelitian ini tidak lepas dari keterbatasan. Seluruh pengambilan gambar dilakukan dalam kondisi yang terkontrol latar belakang putih seragam dan pencahayaan ruangan yang stabil sehingga performa model pada kondisi nyata di lapangan, seperti di kebun atau pasar tradisional dengan pencahayaan yang bervariasi dan latar belakang yang kompleks, belum tentu sebaik hasil yang diperoleh dalam penelitian ini. Selain itu, model hanya diuji pada satu varietas pisang, yaitu Pisang Emas, sehingga kemampuan generalisasinya ke varietas lain seperti Pisang Ambon atau Pisang Kepok masih perlu diuji lebih lanjut.

Untuk penelitian selanjutnya, ada beberapa hal yang layak untuk dijajaki. Pertama, memperluas variasi kondisi pengambilan gambar dengan berbagai latar belakang dan intensitas cahaya akan membuat model lebih tangguh dan siap digunakan di dunia nyata. Kedua, menambahkan fitur tekstur seperti GLCM atau fitur bentuk buah sebagai pelengkap fitur warna RGB berpotensi meningkatkan kemampuan model dalam membedakan kelas matang dan terlalu matang yang secara warna paling mirip satu sama lain. Ketiga, membandingkan performa SVM dengan algoritma deep learning seperti Convolutional Neural Network pada dataset yang lebih besar akan memberikan gambaran yang lebih komprehensif tentang pendekatan terbaik untuk masalah klasifikasi kematangan buah. Terakhir, mengembangkan sistem ini menjadi aplikasi mobile yang dapat digunakan langsung oleh petani atau pedagang di lapangan akan menjadi langkah nyata dalam membawa manfaat penelitian ini ke masyarakat yang membutuhkannya.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Bapak/Ibu dosen pembimbing yang telah meluangkan waktu, tenaga, dan pikiran dalam membimbing penelitian ini dari awal hingga selesai. Masukan dan arahan yang diberikan sangat membantu penulis dalam menyempurnakan penelitian ini menjadi lebih baik. Terima kasih juga kepada seluruh

dosen Program Studi Teknik Informatika, Fakultas Teknik, Universitas Nusantara yang telah memberikan ilmu dan pengalaman selama masa perkuliahan sehingga penulis memiliki bekal yang cukup untuk menyelesaikan penelitian ini.

Penulis juga menyampaikan terima kasih kepada rekan-rekan mahasiswa yang telah membantu proses pengumpulan data, memberikan masukan, serta memberikan semangat selama proses penelitian berlangsung. Tidak lupa, terima kasih kepada keluarga yang selalu menjadi sumber motivasi dan dukungan terbesar bagi penulis. Perlu disampaikan bahwa artikel ini merupakan bagian dari skripsi Program Studi Teknik Informatika, Fakultas Teknik, Universitas Mercu Buana Yogyakarta tahun 2026/2027.

DAFTAR REFERENSI

- Adenugraha, S. P., Arinal, V., & Mulyana, D. I. (2022). Klasifikasi kematangan buah pisang Ambon menggunakan metode K-nearest neighbors dan PCA berdasarkan citra RGB dan HSV. *Jurnal STMIK Budidarma*. <https://www.academia.edu/download/102801259/2367.pdf>
- Agarwal, S., & Verma, A. (2021). Banana ripeness classification using machine learning and image processing techniques. *International Journal of Computer Applications*, 183(12), 1–7. <https://doi.org/10.5120/ijca2021921456>
- Afriansyah, M., Saputra, J., Ardhana, V. Y. P., & Sa'adati, Y. (2024). Algoritma Naïve Bayes yang cepat untuk klasifikasi buah pisang raja berdasarkan fitur warna. *Jurnal Ilmiah Sistem Informasi dan Manajemen Basis Data*. <https://journal.ppmi.web.id/index.php/jismdb/article/view/438>
- Ahsan, M., Based, M. A., Haider, J., & Rodrigues, E. M. G. (2021). Smart monitoring and controlling of agricultural environment using machine learning and IoT technique. *Electronics*, 10(4), Article 499. <https://doi.org/10.3390/electronics10040499>
- Blasco, J., Aleixos, N., Gómez-Sanchis, J., & Moltó, E. (2009). Recognition and classification of external skin damage in citrus fruits using multispectral data and morphological features. *Biosystems Engineering*, 103(2), 137–145. <https://doi.org/10.1016/j.biosystemseng.2009.03.009>
- Bradski, G. (2000). The OpenCV library. *Dr. Dobb's Journal of Software Tools*, 25(11), 120–125.
- Chan, F. R., Yanti, R., & Ramadhanu, A. (2024). *Jurnal of Information System and Informatics Engineering*. <https://doi.org/10.35145/joisie.v8i2.4767>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson Education.
- Heryanto, R., Wahyuningrum, T., & Purnomo, A. S. (2022). Klasifikasi kematangan buah pisang menggunakan support vector machine berbasis ekstraksi fitur warna. *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, 8(1), 45–54. <https://doi.org/10.26555/jiteki.v8i1.23412>

- Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). *A practical guide to support vector classification*. Department of Computer Science, National Taiwan University.
- Khamis, A., Man, Z., & Hussain, K. (2021). A review of machine learning techniques for banana quality grading and classification. *Computers and Electronics in Agriculture*, 185, 106164. <https://doi.org/10.1016/j.compag.2021.106164>
- Milda. (2003). Klasifikasi kematangan buah pisang kepok berdasarkan citra HSV dengan K-nearest neighbors. *Jurnal Unsulbar Informatika Fakultas Teknik*. <https://repository.unsulbar.ac.id/id/eprint/1208/>
- Mohammadi, V., Kheiralipour, K., & Ghasemi-Varnamkhasti, M. (2020). Detecting maturity of persimmon fruit based on image processing technique. *Scientia Horticulturae*, 184, 378–383. <https://doi.org/10.1016/j.scienta.2020.106120>
- Nafianta, C. R. M. A., & Purnomo, B. (2019). Identifikasi dan prediksi tingkat kematangan pisang Candi dengan fitur warna dan tekstur menggunakan metode K-nearest neighbor. <https://www.academia.edu/download/108059479/179.pdf>
- Noor, M. N., Hussain, A., & Mustafa, M. (2022). Automated banana grading system using image processing and machine learning approach. *IEEE Access*, 10, 34512–34524. <https://doi.org/10.1109/ACCESS.2022.3162814>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., VanderPlas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Rahman, M. A., Islam, M. S., & Hossain, M. A. (2023). Banana ripeness detection using RGB color features and support vector machine for smart agriculture applications. *Agriculture*, 13(2), 412. <https://doi.org/10.3390/agriculture13020412>
- Santoso, B., Nugroho, F., & Purnama, I. K. E. (2020). Implementasi metode support vector machine untuk klasifikasi kualitas beras berdasarkan citra digital. *Jurnal Ilmu Komputer dan Agri-Informatika*, 7(1), 1–10. <https://doi.org/10.29244/jika.7.1.1-10>
- Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. MIT Press.
- Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer. <https://doi.org/10.1007/978-1-4757-3264-1>
- Whidhiasih, R. N., Yulianto, D., & Maimunah. (2017). Klasifikasi tahap kematangan pisang Ambon berdasarkan warna menggunakan Naïve Bayes. *Jurnal Penelitian Ilmu Komputer, Sistem Embedded & Logic*, 5(2), 60–67. <https://doi.org/10.33558/piksel.v5i2.268>
- Wulandari, D. A., & Sucipto, A. (2022). Klasifikasi kematangan tomat berdasarkan fitur warna HSV menggunakan support vector machine. *Jurnal Teknologi dan Sistem Komputer*, 10(2), 85–92. <https://doi.org/10.14710/jtsiskom.2022.14278>
- Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., & Liu, C. (2014). Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International*, 62, 326–343. <https://doi.org/10.1016/j.foodres.2014.03.012>