

Perbandingan Kinerja Algoritma KNN dan SVM dalam Klasifikasi Kematangan Buah Jeruk Medan Berdasarkan Citra Digital

Fadilla Julianifa Putri^{1*}, Siti Laila Nurjannah², Dwi Febrina Wati³, Silvia Ariani Daulay⁴, Indira Sistamarien⁵, Endang Purnama Giri⁶, Gema Parasti Mindara⁷

^{1,2,3,4,5}Sekolah Vokasi, Teknologi Rekayasa Perangkat Lunak, IPB University, Kota Bogor, Indonesia

⁶Sekolah Sains Data, Matematika, dan Informatika, Ilmu Komputer, IPB University, Kota Bogor, Indonesia

⁷Sekolah Vokasi, Teknologi Rekayasa Komputer, IPB University, Kota Bogor, Indonesia

E-mail: ^{1*}dillafadilla@apps.ipb.ac.id, ²richiesslalasiti@apps.ipb.ac.id, ³dwifebrina@apps.ipb.ac.id,

⁴arndsilvia@apps.ipb.ac.id, ⁵indirasindira@apps.ipb.ac.id, ⁶endang_pg@apps.ipb.ac.id,

⁷gemaparasti@apps.ipb.ac.id

(* : corresponding author)

Abstrak

Sebagai komoditas unggulan daerah dengan nilai jual menjanjikan, proses pengelompokan tingkat matang Jeruk Medan masih didominasi oleh teknik visual manual. Hal ini kerap memicu inkonsistensi data serta memerlukan durasi pengerjaan yang lama akibat faktor subjektivitas personil. Penelitian ini bertujuan untuk membandingkan kinerja dua algoritma *machine learning*, yaitu KNN dan SVM, dalam mengklasifikasikan tingkat kematangan buah Jeruk Medan berbasis citra digital. Dataset yang digunakan merupakan dataset primer yang dikumpulkan langsung dari petani Jeruk Medan dalam kondisi lapangan. Tahapan penelitian meliputi akuisisi citra, pra-pemrosesan, ekstraksi fitur warna berbasis HSV dan tekstur berbasis GLCM, serta klasifikasi tingkat kematangan ke dalam tiga kelas, yaitu mentah, setengah matang, dan matang. Kinerja kedua algoritma dievaluasi menggunakan metrik akurasi, presisi, dan *recall*. Hasil penelitian menunjukkan bahwa algoritma KNN memiliki performa yang lebih unggul dibandingkan SVM, dengan tingkat akurasi sebesar 96,25%, sedangkan SVM menghasilkan akurasi sebesar 91,25%. Hasil ini menunjukkan bahwa KNN efektif dan lebih sesuai untuk diterapkan pada sistem otomatisasi klasifikasi tingkat kematangan buah Jeruk Medan berbasis citra digital.

Kata kunci: Citra Digital, Jeruk Medan, KNN, Klasifikasi Kematangan, SVM.

Abstract

As a regional flagship commodity with a promising selling value, the process of grouping the maturity level of Medan Orange is still dominated by manual visual techniques. This often triggers data inconsistency and requires a long duration of processing due to personnel subjectivity factors. This research aims to compare the performance of two machine learning algorithms, namely KNN and SVM, in classifying the maturity level of Medan Orange fruit based on digital images. The dataset used is a primary dataset collected directly from Medan Orange farmers in field conditions. The research stages include image acquisition, pre-processing, extraction of HSV-based color features and GLCM-based textures, as well as classification of maturity levels into three classes, namely raw, semi-cooked, and mature. The performance of both algorithms is evaluated using accuracy, precision, and recall metrics. The research results show that the KNN algorithm has a superior performance compared to SVM, with an accuracy rate of 96,25%, while SVM produces an accuracy of 91,25%. This result shows that KNN is effective and more suitable to be applied to the automation system of classification of the maturity of Medan Orange fruit based on digital images.

Keywords: Digital Image, Jeruk Medan, KNN, Ripeness Classification, SVM.

1. PENDAHULUAN

Penentuan mutu buah pada fase pascapanen menjadi faktor penentu yang sangat penting dalam mengukur derajat kematangan, keamanan konsumsi, dan harga pasar komoditas tersebut. Namun, hingga saat ini penentuan kualitas buah pada praktik lapangan umumnya masih mengandalkan pengamatan visual manusia, yang cenderung dipengaruhi oleh subjektivitas dan perbedaan persepsi antar individu. Walaupun prosedur manual lebih praktis tanpa kebutuhan alat bantu yang rumit, ketepatan hasilnya sangat dipengaruhi oleh kompetensi dan jam terbang

personil yang melakukan sortir, sehingga hasil penilaian yang diperoleh sering kali tidak stabil atau bervariasi [1]. Selain itu, proses penyortiran manual cenderung menghasilkan penilaian yang bersifat subjektif dan tidak konsisten akibat pengaruh faktor eksternal, seperti intensitas pencahayaan, yang berdampak pada lamanya waktu proses dan perbedaan hasil sortir [2]. Kondisi ini menjadi kurang efektif apabila diterapkan dalam skala industri yang menuntut ketepatan dan kecepatan dalam proses distribusi. Guna mengatasi keterbatasan tersebut, implementasi sistem cerdas untuk kategorisasi kematangan buah secara mandiri menjadi solusi strategis. Teknologi ini diharapkan mampu menggantikan estimasi manual yang subjektif dengan penilaian yang lebih terukur, seragam, dan memiliki kecepatan proses yang jauh lebih tinggi. Implementasi sistem pengolahan citra digital menjadi salah satu solusi yang mampu meningkatkan objektivitas proses klasifikasi dan telah terbukti dapat mencapai tingkat akurasi hingga 80,8% dalam mendeteksi kematangan buah [3].

Buah jeruk merupakan salah satu komoditas unggulan di Indonesia yang memiliki peluang pengembangan besar karena dapat dipanen dan dipasarkan sepanjang tahun. Tanaman jeruk juga relatif mudah dibudidayakan serta mampu beradaptasi dengan berbagai kondisi iklim, baik di dataran tinggi maupun dataran rendah [4]. Salah satu varietas jeruk yang banyak dibudidayakan dan memiliki nilai ekonomi tinggi adalah Jeruk Medan yang berasal dari wilayah Sumatera Utara. Jeruk Medan memiliki karakteristik khusus, antara lain ukuran buah sedang, tangkai yang kokoh, bentuk cenderung pipih, kulit relatif tebal, rasa manis, serta bulir berukuran besar [5]. Selain cita rasanya yang khas, Jeruk Medan juga memiliki karakteristik visual berupa perubahan warna kulit dari hijau kekuningan hingga oranye seiring meningkatnya tingkat kematangan, serta tekstur permukaan kulit yang bervariasi. Perubahan warna dan tekstur tersebut menjadi indikator penting dalam menentukan tingkat kematangan buah jeruk. Namun demikian, konsumen maupun pelaku usaha sering kali mengalami kesulitan dalam membedakan jeruk yang matang dan belum matang apabila hanya mengandalkan pengamatan visual secara manual. Untuk meminimalkan kesalahan tersebut, teknologi *computer vision* dapat dimanfaatkan melalui sistem deteksi berbasis kamera yang mampu membantu proses identifikasi kematangan buah secara lebih objektif dan akurat [4].

Seiring dengan perkembangan teknologi, pendekatan pengolahan citra digital semakin banyak dimanfaatkan sebagai solusi dalam mengidentifikasi tingkat kematangan buah karena mampu mengekstraksi informasi visual secara kuantitatif. Kebutuhan akan metode penilaian yang objektif dan akurat menjadi semakin penting, terutama dalam menjamin kualitas jeruk yang berkaitan dengan rasa dan tingkat kematangannya [6]. Penilaian manual yang selama ini digunakan sering kali menghasilkan interpretasi yang berbeda antar individu serta dipengaruhi oleh faktor eksternal seperti pencahayaan, sehingga kurang efektif untuk diterapkan pada proses yang membutuhkan ketelitian tinggi [2]. Oleh karena itu, implementasi teknik identifikasi berbasis citra digital menjadi solusi yang tepat untuk mengatasi keterbatasan tersebut. Melalui pengolahan citra digital, proses pengenalan kualitas atau tingkat kematangan buah dapat dilakukan secara otomatis, lebih cepat, dan tanpa memerlukan pengamatan langsung, sehingga mampu meningkatkan efisiensi serta konsistensi hasil evaluasi.

Berbagai penelitian sebelumnya telah membuktikan efektivitas algoritma *machine learning* seperti *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM) dalam klasifikasi citra, khususnya untuk mengidentifikasi tekstur dan tingkat kematangan buah jeruk. Metode SVM telah digunakan untuk mengklasifikasikan kategori rasa Jeruk Berastagi, yaitu asam, manis, dan hambar, berdasarkan fitur warna dan tekstur yang diekstraksi dari citra jeruk dengan menggunakan 300 data citra yang terbagi merata pada setiap kategori. Hasil penelitian tersebut menunjukkan bahwa penerapan metode SVM mampu meningkatkan akurasi klasifikasi secara signifikan [6]. Penelitian lain mengenai klasifikasi jeruk segar dan busuk menggunakan kombinasi fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) dan fitur warna HSV menunjukkan bahwa penggabungan kedua jenis fitur tersebut mampu meningkatkan akurasi klasifikasi. Fitur tekstur berperan dalam membedakan struktur permukaan kulit, sedangkan fitur warna HSV mengekstraksi informasi warna secara lebih detail [7]. Selain itu, penelitian mengenai klasifikasi tingkat kematangan buah alpukat menggunakan ekstraksi fitur warna berbasis *mean RGB* yang dikombinasikan dengan algoritma KNN menunjukkan bahwa transformasi ruang

warna dari RGB ke Lab mampu meningkatkan ketelitian analisis warna dan mempermudah proses segmentasi. Evaluasi menggunakan *confusion matrix* menghasilkan nilai akurasi, presisi, dan *recall* yang baik, sehingga menunjukkan performa metode yang optimal [8]. Berbeda dengan penelitian sebelumnya yang umumnya menggunakan dataset sekunder dari sumber publik atau eksperimen laboratorium, penelitian ini menggunakan dataset primer citra Jeruk Medan yang dikumpulkan langsung dari lapangan. Dataset ini merepresentasikan kondisi nyata yang dihadapi petani dalam proses panen dan penyortiran, sehingga memberikan kontribusi praktis bagi pengembangan sistem klasifikasi kematangan jeruk lokal berbasis citra digital.

Meskipun berbagai penelitian sebelumnya telah menerapkan metode KNN, SVM, serta kombinasi fitur warna dan tekstur dalam klasifikasi kualitas buah, masih terdapat kesenjangan penelitian karena belum adanya studi yang secara khusus membandingkan kinerja kedua algoritma tersebut dalam mengklasifikasikan tingkat kematangan Jeruk Medan. Sebagian besar penelitian terdahulu berfokus pada jenis buah lain atau pada aspek yang berbeda, seperti klasifikasi rasa, pemisahan buah segar dan busuk, atau penilaian kualitas secara umum, tanpa mempertimbangkan karakteristik visual Jeruk Medan yang memiliki variasi warna dan tekstur kulit yang khas selama proses pematangan [5]. Selain itu, belum terdapat kajian yang secara komprehensif menganalisis pengaruh pemilihan fitur warna dan tekstur terhadap perbedaan kinerja algoritma KNN dan SVM dalam konteks citra buah Jeruk Medan.

Ketergantungan petani pada intuisi visual dalam menentukan masa panen Jeruk Medan saat ini masih menjadi tantangan besar karena sifatnya yang subjektif. Realita ini menunjukkan adanya kesenjangan penelitian (*research gap*) yang nyata, yaitu belum tersedianya studi komparatif yang secara spesifik menguji algoritma KNN dan SVM menggunakan dataset primer langsung dari lahan pertanian. Sebagian besar literatur terdahulu cenderung berfokus pada dataset publik atau pengujian di lingkungan laboratorium yang terkontrol, sehingga kurang merepresentasikan variasi pencahayaan dan kompleksitas latar belakang pada kondisi riil. Oleh karena itu, penelitian ini hadir untuk menutup celah tersebut dengan melakukan analisis perbandingan performa kedua algoritma tersebut sebagai solusi klasifikasi yang akurat namun tetap efisien secara komputasi. Fokus penelitian ini diharapkan dapat memberikan kontribusi praktis bagi standarisasi mutu Jeruk Medan serta menjadi referensi dalam pengembangan sistem otomatisasi pertanian berbasis sumber daya terbatas di tingkat lokal.

2. METODE PENELITIAN

2.1. Desain Penelitian


Pendekatan kuantitatif eksperimental dipilih dalam penelitian ini untuk mengevaluasi efektivitas klasifikasi antara teknik SVM dan KNN pada citra digital Jeruk Medan. Proses identifikasi dilakukan dengan membagi sampel ke dalam tiga label kematangan mentah, setengah matang, serta matang yang didasarkan pada hasil analisis parameter fitur tekstur dan warna citra. Pemilihan fitur warna (RGB/HSV) serta tekstur berbasis *Gray Level Co-occurrence Matrix* (GLCM) didasarkan pada penelitian serupa yang menunjukkan efektivitas kombinasi warna dan tekstur untuk pengenalan kualitas buah jeruk [9].

Selain itu, penggunaan algoritma KNN dan SVM dipertimbangkan karena performanya yang konsisten pada klasifikasi berbasis fitur visual. Prinsip kerja KNN adalah dengan menetapkan label sampel berdasarkan dominasi kelas dari sekumpulan tetangga terdekatnya. Di sisi lain, algoritma SVM berupaya menciptakan bidang pemisah (*hyperplane*) yang paling efisien untuk membagi data ke dalam beberapa kategori. Kedua algoritma umum digunakan pada klasifikasi citra yang telah direpresentasikan menjadi vektor fitur berdimensi lebih rendah, sehingga relevan untuk dibandingkan dalam penelitian ini [10].

Pendekatan klasifikasi menggunakan algoritma KNN dan SVM dipilih karena keduanya masih relevan untuk dataset citra berukuran terbatas dan kondisi implementasi lapangan yang memiliki keterbatasan sumber daya komputasi. Dibandingkan banyak arsitektur *deep learning*, KNN dan SVM umumnya memiliki struktur model yang lebih sederhana dan lebih mudah diimplementasikan dalam sistem praktis berskala kecil hingga menengah, sehingga sesuai untuk

konteks pertanian lokal dan sistem klasifikasi tingkat kematangan buah berbasis citra digital. Namun, pada dataset besar KNN dan SVM dapat menjadi komputasi-intensif sehingga keunggulan ini terutama berlaku pada skala data dan sumber daya yang terbatas [11].

Secara umum alur penelitian meliputi: (1) pelabelan data citra, (2) pra-pemrosesan citra, (3) ekstraksi fitur warna dan tekstur, (4) penyusunan dataset fitur, (5) pembagian data latih-uji, (6) normalisasi fitur, (7) pelatihan model dengan optimasi *hyperparameter*, (8) pengujian model, dan (9) perbandingan hasil.



Gambar 1. Diagram Flow Alur Penelitian

2.2. Dataset dan Pelabelan

Sumber data primer yang dianalisis dalam penelitian ini mencakup 292 citra Jeruk Medan yang diambil langsung di lapangan dengan kondisi pencahayaan alami serta variasi sudut pengambilan gambar. Peneliti mengumpulkan dataset primer secara langsung di lapangan. Langkah ini merepresentasikan kondisi riil yang dihadapi petani dan pedagang saat menyortir buah. Proses akuisisi data melibatkan penggunaan cahaya alami dan keberagaman sudut kamera guna menyimulasikan kendala identifikasi kematangan jeruk di dunia nyata. Penentuan label tingkat kematangan dilakukan secara manual oleh petani Jeruk Medan yang berpengalaman, sehingga label yang dihasilkan merepresentasikan penilaian ahli yang umum digunakan dalam praktik panen. Hal ini sejalan dengan kondisi lapangan, di mana petani jeruk menentukan tingkat kematangan berdasarkan pengalaman dan pengamatan visual untuk memastikan waktu panen yang tepat dan menjaga kualitas buah [12].

Citra kemudian dikelompokkan ke dalam tiga kelas kematangan, yaitu mentah sebanyak 122 citra, setengah matang sebanyak 92 citra, dan matang sebanyak 78 citra. Setelah proses pelabelan, metadata disimpan dalam berkas CSV yang berisi nama file citra dan kelas kematangan. Ketidakseimbangan jumlah citra antar kelas dicatat dan dipertimbangkan dalam tahap evaluasi model menggunakan metrik *F1-score* per kelas.

2.3. Pra-Pemrosesan Citra

Pra-pemrosesan dilakukan untuk menyeragamkan kondisi citra sebelum tahap ekstraksi fitur, sehingga perhitungan ciri menjadi konsisten antar sampel. Setiap citra terlebih dahulu diubah ukurannya (*resize*) ke resolusi yang sama agar dimensi citra seragam dan tidak menimbulkan perbedaan nilai fitur akibat variasi ukuran gambar [13]. Setelah ukuran citra diseragamkan, citra dikonversi dari ruang warna RGB ke HSV untuk analisis warna. Ruang warna HSV diterapkan guna menguraikan data warna dari format RGB ke dalam tiga elemen utama: *Hue* untuk jenis warna, *Saturation* untuk intensitas/kejenuhan, serta *Value* untuk tingkat terang-gelapnya citra.

Karakteristik ini membuat HSV relevan dipakai untuk mendeteksi perubahan warna kulit buah sebagai indikator kematangan. Untuk kebutuhan analisis tekstur, citra juga diubah ke *grayscale* karena metode tekstur seperti GLCM bekerja pada intensitas keabuan. Konversi RGB menjadi *grayscale* merupakan prosedur yang lazim dalam ekstraksi tekstur citra sebelum perhitungan matriks *co-occurrence* [14].

2.4. Ekstraksi Fitur

Ekstraksi fitur bertujuan mengubah citra jeruk menjadi vektor numerik yang mewakili karakteristik kematangan. Pada penelitian ini digunakan dua kelompok fitur, yaitu fitur warna berbasis HSV dan fitur tekstur berbasis GLCM serta LBP. Kombinasi warna dan tekstur diharapkan mampu menangkap perbedaan kematangan jeruk baik dari perubahan warna kulit maupun perubahan struktur permukaan. Kombinasi fitur warna dan tekstur digunakan untuk meningkatkan kemampuan model dalam membedakan kelas kematangan yang memiliki karakteristik visual berdekatan, khususnya pada fase setengah matang.

a. Ekstraksi Fitur Warna (HSV)

Ekstraksi fitur warna dilakukan pada ruang warna HSV karena mampu merepresentasikan warna sesuai persepsi manusia dan lebih stabil terhadap perubahan pencahayaan, sehingga cocok untuk membedakan tingkat kematangan buah yang ditandai oleh perubahan warna kulit [15]. Pada penelitian ini, informasi warna dari citra RGB terlebih dahulu dikonversi ke HSV, lalu diekstraksi menggunakan pendekatan *color moment* dengan menghitung statistik utama berupa nilai rata-rata (*mean*) dan simpangan baku (*standard deviation*) pada setiap kanal H, S, dan V. Statistik ini menghasilkan representasi fitur warna yang ringkas tetapi tetap informatif sebagai masukan model klasifikasi.

b. Ekstraksi Fitur Tekstur (GLCM dan LBP)

Analisis tekstur dilakukan untuk menangkap perubahan pola permukaan kulit jeruk selama pematangan. Pada penelitian ini digunakan dua jenis fitur tekstur, yaitu GLCM dan LBP. GLCM memodelkan hubungan kemunculan pasangan intensitas piksel pada jarak serta arah tertentu, lalu nilainya diringkas menjadi beberapa parameter tekstur utama seperti *contrast*, *correlation*, *energy*, dan *homogeneity* sebagai representasi kekasaran serta keseragaman permukaan. Selain itu, LBP digunakan karena merupakan deskriptor tekstur lokal yang kuat dan banyak dipakai dalam berbagai aplikasi pengenalan pola. LBP bekerja dengan membandingkan nilai piksel pusat terhadap piksel-piksel tetangganya dalam jendela kecil (umumnya 3×3) sehingga menghasilkan kode biner yang merepresentasikan motif tekstur lokal, kemudian seluruh kode tersebut dirangkum menjadi histogram sebagai vektor fitur untuk klasifikasi [16].

2.5. Penyusunan Dataset Fitur

Seluruh fitur warna dan tekstur yang diperoleh dari tiap citra digabungkan menjadi satu vektor fitur. Setiap baris pada dataset merepresentasikan satu citra jeruk, sedangkan kolom berisi nilai fitur warna HSV, fitur tekstur GLCM, dan histogram LBP. Dataset fitur disimpan ke dalam format CSV sebagai masukan pada tahap pelatihan dan pengujian model.

2.6. Pembagian Data Latih dan Data Uji

Dataset fitur dibagi menjadi data latih dan data uji dengan rasio 80%:20%. Pembagian dilakukan secara *stratified* agar proporsi masing-masing kelas kematangan tetap terjaga pada kedua bagian dataset, sehingga evaluasi lebih adil pada kondisi kelas yang tidak seimbang.

2.7. Normalisasi Fitur

Sebelum pelatihan, seluruh fitur dinormalisasi menggunakan *StandardScaler* agar berada pada skala yang sebanding. Normalisasi dilakukan dengan mengubah setiap fitur menjadi distribusi ber-*mean* 0 dan standar deviasi 1. Langkah ini diperlukan karena KNN berbasis jarak dapat bias terhadap fitur berskala besar, sementara SVM sensitif terhadap perbedaan skala pada ruang fitur.

2.8. Pelatihan Model dan Optimasi *Hyperparameter*

Pelatihan model dilakukan pada data latih menggunakan dua algoritma, yaitu KNN dan SVM. Untuk memperoleh konfigurasi model yang paling optimal dan memastikan perbandingan berlangsung adil, masing-masing algoritma dituning menggunakan *Grid Search* yang dikombinasikan dengan *cross-validation*, sehingga setiap kombinasi parameter diuji secara otomatis dan dipilih yang memberikan performa terbaik [17]. Penggunaan *Grid Search* dengan *cross-validation* bertujuan memastikan bahwa perbandingan performa antara KNN dan SVM dilakukan secara objektif dan tidak dipengaruhi oleh pemilihan parameter yang bias.

Pada KNN, hiperparameter utama yang ditentukan adalah jumlah tetangga kkk (*number of nearest neighbors*), karena perbedaan nilai kkk dapat menghasilkan keputusan kelas yang berbeda pada data yang sama, selain itu diuji pula metrik jarak (misalnya *Euclidean* atau *Manhattan*) dan skema pembobotan tetangga. Pada SVM, proses *Grid Search* diarahkan untuk memilih kernel yang paling sesuai (linear, RBF, atau polynomial) serta nilai parameter regulasi CCC dan γ yang mengatur tingkat toleransi kesalahan dan kompleksitas pemisahan kelas pada ruang fitur.

2.9. Pengujian Model dan Evaluasi

Model terbaik dari masing-masing algoritma diuji menggunakan data uji. Evaluasi dilakukan memakai metrik akurasi, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk melihat pola kesalahan antar kelas [18]. Mengingat adanya ketidakseimbangan jumlah data pada tiap kelas kematangan, evaluasi tidak hanya berfokus pada metrik global, tetapi juga meninjau nilai *F1-score* per kelas dan *macro-F1* agar kontribusi setiap kelas memiliki bobot yang setara. Pendekatan ini memastikan bahwa performa model tidak bias terhadap kelas dengan jumlah data yang lebih besar serta mampu memberikan gambaran yang lebih komprehensif mengenai kualitas klasifikasi.


2.10. Perbandingan KNN dan SVM

Perbandingan kinerja dilakukan dengan meninjau nilai akurasi dan *macro-F1* dari kedua model. Algoritma dengan nilai evaluasi lebih tinggi serta performa yang lebih stabil pada seluruh kelas dipilih sebagai model terbaik untuk klasifikasi kematangan Jeruk Medan. Hasil perbandingan juga ditinjau melalui *confusion matrix* untuk mengetahui kelas yang paling sering tertukar.

3. HASIL DAN PEMBAHASAN

Data yang digunakan pada penelitian ini merupakan citra buah jeruk yang dikelompokkan ke dalam tiga kategori, yaitu mentah, setengah matang, dan matang. Seluruh citra dikumpulkan melalui proses dokumentasi dan kemudian ditempatkan pada folder *training* dan *testing* sesuai kategori. Total data setelah *preprocessing* adalah 396 citra, dengan pembagian data latih dan data uji menggunakan rasio 80% : 20%.

Tahap awal penelitian ini adalah *preprocessing* citra. Tahapan ini dilakukan untuk menyeragamkan ukuran, format, serta meningkatkan kesiapan citra sebelum masuk ke proses ekstraksi fitur. Setiap gambar diubah ukurannya menjadi 256×256 piksel agar seluruh citra memiliki dimensi yang konsisten. Konversi warna dari RGB ke HSV dilakukan untuk memisahkan komponen warna, kejenuhan, dan kecerahan, yang sangat relevan dalam mendeteksi tingkat kematangan jeruk. Selain itu, citra juga dikonversi ke *grayscale* karena analisis tekstur menggunakan GLCM memerlukan citra berskala keabuan. Seluruh citra hasil *preprocessing* kemudian disimpan pada folder khusus (HSV dan *grayscale*) sehingga dapat diproses lebih lanjut secara terstruktur.



Gambar 2. Hasil Gambar Resize, Hsv dan Grayscale

Ekstraksi fitur warna dilakukan pada ruang warna HSV dengan menghitung nilai *mean* dan standar deviasi untuk setiap channel (H, S, dan V). Nilai statistik hasil ekstraksi fitur warna ditampilkan pada Tabel 1.

Tabel 1. Hasil ekstraksi fitur warna

Kategori	mean_h	mean_s	mean_v	std_h	std_s	std_v
mentah	46.236	183.907	169.915	47.082	31.811	41.023
setengah_matang	49.700	187.606	177.357	54.102	30.907	40.588
matang	47.667	199.860	184.049	50.495	31.109	42.575

Nilai *mean_v* menunjukkan perbedaan yang jelas antar kategori, di mana kelas matang memiliki nilai *mean_v* tertinggi yaitu 184.049, sedangkan kelas mentah memiliki *mean_v* paling rendah yaitu 169.915. Hal ini menggambarkan bahwa buah jeruk yang matang memiliki tingkat kecerahan lebih tinggi dibandingkan buah mentah. Channel S juga menunjukkan kecenderungan peningkatan pada kelas matang, mengindikasikan kejenuhan warna yang meningkat seiring pematangan. Variasi warna pada channel H tercermin dari nilai standar deviasi, di mana kelas setengah matang memiliki nilai tertinggi sehingga menggambarkan variasi warna yang lebih beragam pada tahap transisi kematangan.

Ekstraksi fitur tekstur dilakukan menggunakan metode GLCM. Hasil nilai statistik fitur tekstur diringkas pada Tabel 2.


Tabel 2. Hasil Ekstraksi Fitur Tekstur

Kategori	contrast	correlation	energy	homogeneity
mentah	737.967	0.8678	0.0183	0.1433
setengah_matang	537.956	0.8855	0.0162	0.1405
matang	801.578	0.8597	0.0378	0.1727

Kategori matang memiliki nilai *contrast* tertinggi sebesar 801.578, yang menunjukkan adanya variasi intensitas piksel yang lebih kuat pada permukaan kulit jeruk, sesuai dengan perubahan tekstur pada buah saat matang. Nilai *correlation* tertinggi terdapat pada kelas setengah matang dengan nilai 0.8855, menandakan adanya hubungan antar piksel yang lebih konsisten pada kelas tersebut. Nilai *homogeneity* tertinggi ditemukan pada kelas matang, yang menunjukkan bahwa permukaan kulit jeruk matang memiliki pola tekstur yang lebih halus dan seragam dibandingkan dua kategori lainnya. Hasil ini mengonfirmasi bahwa tekstur permukaan buah dapat dijadikan fitur pembeda tingkat kematangan.


Setelah seluruh fitur warna dan tekstur digabungkan, dataset kemudian dinormalisasi menggunakan *StandardScaler* untuk menyamakan skala fitur, terutama karena dataset berisi ratusan nilai histogram HSV. Dataset akhir yang telah dinormalisasi kemudian dibagi kembali menjadi data latih dan data uji, dan selanjutnya digunakan untuk pelatihan model KNN dan SVM. Pelatihan dilakukan menggunakan *GridSearchCV* untuk mencari parameter terbaik pada kedua algoritma. Hasil pencarian parameter disajikan pada Gambar 3 dan Gambar 4.

Untuk KNN, kombinasi parameter terbaik diperoleh pada $k = 7$, *metric manhattan*, dan bobot *distance*, dengan skor validasi sebesar 0.9019.



Gambar 3. Grid Search KNN

Sementara itu, SVM menunjukkan performa terbaik pada kernel RBF dengan parameter $C = 1$ dan $\gamma = \text{auto}$.




Gambar 4. Grid Search SVM

Setelah parameter optimal dari kedua algoritma diperoleh melalui proses *Grid Search*, langkah selanjutnya adalah melakukan evaluasi performa model pada data uji untuk mengetahui seberapa baik masing-masing algoritma mampu melakukan klasifikasi tingkat kematangan buah jeruk pada kondisi sebenarnya.

Berikut hasil perbandingan kedua algoritma disajikan pada Tabel 3 dan Gambar 5.

Tabel 3. Perbandingan Algoritma KNN dan Algoritma SVM

Metrik	KNN	SVM
Akurasi	96.25%	91.25%
Precision	95.48%	90.65%
Recall	94.96%	89.63%
F1-Score	95.18%	89.85%



Gambar 5. Kinerja KNN dan SVM

Berdasarkan hasil tersebut, algoritma KNN menunjukkan performa terbaik dengan akurasi sebesar 96.25%, lebih tinggi dibandingkan SVM yang memperoleh akurasi 91.25%. Nilai *precision*, *recall*, dan *F1-score* pada KNN juga konsisten lebih tinggi, masing-masing sebesar 95.48%, 94.96%, dan 95.18%. Hal ini menunjukkan bahwa KNN lebih mampu mengenali setiap kelas kematangan dengan baik, termasuk kelas setengah matang yang sering kali menjadi kelas paling sulit dibedakan. Sebaliknya, SVM masih menghasilkan performa yang baik, namun lebih sensitif terhadap parameter dan cenderung kurang stabil pada dataset berdimensi besar seperti pada penelitian ini.

Performa ini juga terlihat jelas pada hasil *confusion matrix* pada Tabel 4 dan Tabel 5. Pada Tabel 4, KNN menunjukkan kemampuan klasifikasi yang sangat stabil dengan tingkat kesalahan yang minimal pada seluruh kelas. Pada kelas matang tercatat tanpa kesalahan prediksi sama sekali, sementara kelas setengah matang dan mentah hanya mengalami sedikit kesalahan klasifikasi. Sebaliknya, pada Tabel 5 terlihat bahwa SVM menghasilkan jumlah kesalahan klasifikasi yang lebih tinggi, terutama pada kelas mentah dan setengah matang yang memiliki karakteristik visual lebih berdekatan. Kondisi ini terjadi karena kelas setengah matang memiliki karakteristik warna dan tekstur yang berada pada fase transisi antara mentah dan matang, sehingga batas antar kelas menjadi kurang tegas dan lebih sulit dibedakan oleh model.

Meskipun SVM tetap mampu mengklasifikasikan kelas matang dengan sempurna, akumulasi kesalahan pada dua kelas lainnya menyebabkan penurunan nilai *precision*, *recall*, dan *F1-score* secara keseluruhan. Dengan demikian, analisis *confusion matrix* memperkuat hasil evaluasi metrik sebelumnya bahwa KNN merupakan algoritma yang lebih optimal dalam mengidentifikasi tingkat kematangan Jeruk Medan pada dataset ini.

Tabel 4. Confusion Matrix KNN pada Data Uji per Kelas

Actual/Predicted	mentah	setengah_matang	matang
mentah	24	1	0
setengah_matang	2	16	0
matang	0	0	37

Tabel 5. Confusion Matrix SVM pada Data Uji per kelas

Actual/Predicted	mentah	setengah_matang	matang
mentah	20	3	2
setengah_matang	1	16	1
matang	0	0	37

Secara keseluruhan, hasil penelitian menunjukkan bahwa tahap *preprocessing* berhasil mempersiapkan citra dengan baik sehingga fitur warna dan tekstur dapat diekstraksi secara optimal.

Tabel 6. Perbandingan antar HSV dan RGB

Kategori	mean_h	mean_s	mean_v	mean_r	mean_g	mean_b
mentah	46.236	183.907	169.915	116.950	144.760	87.743
setengah_matang	49.700	187.606	177.357	123.683	153.253	93.430
matang	47.667	199.860	184.049	142.050	147.476	104.726

Berdasarkan analisis perbandingan antar ruang warna hsv dan rgb pada tabel 6, fitur warna HSV terbukti memberikan informasi yang kuat untuk membedakan tingkat kematangan buah jeruk, terutama pada channel V yang berkaitan dengan kecerahan kulit buah yang lebih stabil. Fitur tekstur yang diekstraksi menggunakan GLCM memberikan informasi tambahan mengenai pola permukaan kulit, yang memperkaya representasi fitur. Kombinasi kedua fitur ini menghasilkan dataset yang mampu diklasifikasikan dengan sangat baik oleh algoritma KNN. Dengan akurasi mencapai 96.25%, KNN terbukti menjadi algoritma paling efektif dalam penelitian ini.

4. KESIMPULAN DAN SARAN

Berdasarkan rangkaian tahapan penelitian mulai dari pra-pemrosesan citra, ekstraksi fitur warna HSV dan tekstur GLCM, hingga proses klasifikasi menggunakan algoritma KNN dan SVM, dapat disimpulkan bahwa fitur warna dan tekstur mampu merepresentasikan perbedaan tingkat kematangan buah Jeruk Medan secara akurat. Channel warna V pada HSV terbukti memberikan pengaruh besar dalam membedakan kecerahan kulit jeruk, sementara fitur tekstur seperti *contrast* dan *homogeneity* pada GLCM membantu menangkap perubahan permukaan kulit yang terjadi selama pematangan.

Hasil evaluasi kinerja klasifikasi menunjukkan bahwa algoritma KNN memberikan performa terbaik dibandingkan SVM. Algoritma KNN mencapai akurasi sebesar 96.25%, *precision* 95.48%, *recall* 94.96%, dan *F1-score* 95.18% dengan konfigurasi parameter optimal berupa jumlah tetangga (k) = 7, metrik jarak *Manhattan*, serta skema pembobotan *distance*. Konfigurasi ini terbukti mampu mengklasifikasikan ketiga tingkat kematangan jeruk, yaitu mentah, setengah matang, dan matang, secara konsisten dengan tingkat kesalahan yang minimal. Sementara itu, algoritma SVM menunjukkan performa terbaik pada penggunaan kernel *Radial Basis Function* (RBF) dengan nilai parameter $C = 1$ dan *gamma* = auto, menghasilkan akurasi sebesar 91.25%. Meskipun SVM mampu mengklasifikasikan kelas matang dengan baik, performanya relatif lebih rendah pada kelas mentah dan setengah matang yang memiliki karakteristik visual yang saling berdekatan.

Berdasarkan hasil tersebut, dapat disimpulkan bahwa algoritma KNN dengan parameter optimal lebih efektif dan stabil dibandingkan SVM dalam mengklasifikasikan tingkat kematangan buah Jeruk Medan berbasis citra digital. Oleh karena itu, kombinasi fitur HSV dan GLCM dengan algoritma KNN berparameter $k = 7$, metrik *Manhattan*, dan bobot *distance* direkomendasikan sebagai pendekatan yang praktis dan aplikatif untuk sistem otomatisasi penyortiran kematangan jeruk di lingkungan pertanian lokal.

Untuk pengembangan lebih lanjut, penelitian ini masih memiliki peluang yang luas untuk diperluas pada berbagai aspek teknis. Salah satunya adalah penggunaan dataset dengan jumlah yang lebih besar serta variasi kondisi pencahayaan dan sudut pengambilan gambar yang lebih beragam, sehingga model dapat dilatih untuk mengenali karakteristik buah pada kondisi yang semakin mendekati situasi nyata di lapangan. Selain itu, penerapan metode segmentasi yang lebih adaptif, seperti *GrabCut* atau pendekatan berbasis *deep learning*, dapat dipertimbangkan untuk meningkatkan ketepatan pemisahan area objek dari latar belakang. Dari sisi klasifikasi, eksplorasi algoritma tambahan seperti *Random Forest* atau metode *ensemble* berpotensi memberikan wawasan yang lebih luas terhadap performa model berbasis fitur warna dan tekstur. Pada penelitian selanjutnya, pendekatan berbasis *deep learning* seperti *Convolutional Neural Network*

(CNN) dapat dikembangkan dan dibandingkan dengan metode klasik yang digunakan dalam penelitian ini, khususnya apabila tersedia dataset yang lebih besar dan beragam. Dengan pengembangan tersebut, sistem klasifikasi kematangan jeruk diharapkan dapat semakin optimal dan siap mendukung implementasi pada proses penyortiran di lapangan maupun industri pascapanen.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Institut Pertanian Bogor (IPB University) yang telah memberikan dukungan dalam penyelesaian penelitian ini. Ucapan terima kasih juga disampaikan kepada dosen pembimbing yang turut memberikan masukan serta bantuan selama proses penelitian dan penulisan jurnal ini berlangsung.

DAFTAR PUSTAKA

- [1] K. M. Harahap, D. Pangestu, D. Alfarizdi, and F. Iqbal, "Penerapan Pengolahan Citra Digital Berbasis MATLAB untuk Sortasi Ukuran dan Warna Buah Alpukat," *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer)*, vol. 5, no. 1, pp. 22–26, 2025, doi: 10.55382/jurnalpustakadata.v5i1.967.
- [2] J. Rusman and N. Pasae, "Prototype Sistem Penyortir Buah Kopi Arabika Berdasarkan Tingkat Kematangan Menggunakan Metode Support Vector Machine," *Teknika*, vol. 12, no. 1, pp. 65–72, 2023, doi: 10.34148/teknika.v12i1.602.
- [3] S. Siagian, K. Ibnutama, and R. Mahyuni, "Implementasi Metode Ekstraksi Ciri Warna Untuk Mendeteksi Kematangan Buah Jeruk," *Jurnal Sistem Informasi Triguna Dharma (JURSI TGD)*, vol. 1, no. 6, p. 898, 2022, doi: 10.53513/jursi.v1i6.5861.
- [4] K. P. Siwilopo and H. Marcos, "Membandingkan Klasifikasi pada Buah Jeruk Menggunakan Metode Convolutional Neural Network dan K-Nearest Neighbor," *Komputa : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 1, pp. 57–64, 2023, doi: 10.34010/komputa.v12i1.9068.
- [5] S. Aisyah and R. R. Winardi, "Pemanfaatan Stearin Kelapa Sawit sebagai Edible Coating Buah Jeruk Medan (*Citrus sinensis* L.)," *Jurnal Teknologi Pertanian Andalas*, vol. 27, no. 1, pp. 1–6, 2023, doi: 10.25077/jtpa.27.1.1-6.2023.
- [6] M. L. Malau, S. Wulandari, and D. Kiswanto, "Penerapan Pengolahan Citra Digital Untuk Klasifikasi Rasa Jeruk Berastagi Berdasarkan Warna Dan Tekstur Dengan Metode Klasifikasi SVM," *Jurnal Pendidikan Teknologi Informasi dan Vokasional*, vol. 7, no. 1, pp. 86–101, 2025, doi: 10.23960/jptiv.v7i1.32589.
- [7] A. K. Ulandari, *et al.*, "Klasifikasi Jeruk Segar dan Busuk Melalui GLCM dan HSV dengan Menggunakan Metode ANN," *Seminar Nasional Teknologi & Sains*, vol. 3, no. 1, pp. 97–102, 2024, doi: 10.29407/stains.v3i1.4358.
- [8] A. Angga, A. Syarif, and A. Ramadhanu, "Klasifikasi Citra Tingkat Kematangan Buah Alpukat Berdasarkan Bentuk dan Warna Menggunakan Metode K-Nearest Neighbor," *Journal of Science and Social Research*, vol. 7, no. 4, pp. 1578–1583, 2024, doi: 10.54314/jssr.v7i4.2280.
- [9] D. F. A. Riza, *et al.*, Y. Hendrawan, and N. Kondo, "Prediction of The Maturity Level of Pontianak Oranges (*Citrus Suhuniensis* CV Pontianak) Using Color and Texture Features of Digital Reflectance-Fluorescence Images and Partial Least Square (PLS) Model," in *Proceedings of the 2023 Brawijaya International Conference (BIC 2023)*, 2024, pp. 125–132. doi: 10.2991/978-94-6463-525-6_14.
- [10] N. R. Feta, "Comparison of KNN and SVM Algorithms in Facial Image Recognition Using Haar Wavelet Feature Extraction," *Jurnal Riset Informatika*, vol. 5, no. 3, pp. 321–330, 2023, doi: 10.34288/jri.v5i3.224.
- [11] P. Wang, E. Fan, and P. Wang, "Comparative analysis of image classification algorithms based on traditional machine learning and deep learning," *Pattern Recognit. Lett.*, vol. 141, pp. 61–67, 2021, doi: 10.1016/j.patrec.2020.07.042.

- [12] D. A. Ardian, *et al.*, “Klasifikasi Tingkat Kematangan Buah Jeruk Menggunakan Arsitektur VGG16,” in *SENTIMETER (Seminar Nasional Teknologi Informasi, Mekatronika dan Ilmu Komputer)*, 2025.
- [13] V. D. Yanto and I. Handayani, “Implementation of The K-Means Clustering Algorithm in Determining the Rate of Indramayu Mango Fruit,” *JSRET (Journal of Scientific, Research, Education, and Technology)*, vol. 3, no. 4, pp. 1929–1938, 2024, doi: 10.58526/jsret.v3i4.609.
- [14] A. M. A. Efendi, S. Sriani, and M. S. Hasibuan, “Classification of Watermelon Ripeness Levels Using HSV Color Space Transformation and K-Nearest Neighbor Method,” *Journal of Computer Networks, Architecture and High Performance Computing*, vol. 6, no. 3, pp. 934–948, 2024, doi: 10.47709/cnahpc.v6i3.3999.
- [15] J. I. Mujidah *et al.*, “Klasifikasi Tingkat Kematangan Lada Menggunakan Ensemble Learning Berdasarkan Citra Warna Kulit,” *Jurnal Informatika Progres*, vol. 17, no. 2, pp. 1–11, 2025, doi: 10.56708/progres.v17i2.467.
- [16] A. T. Nugroho, *et al.*, “Fitur Tekstur Daun Aglaonema dengan Kode Local Binary Pattern Texture Features of Aglaonema Leaves with Local Binary Pattern Code,” *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 4, pp. 1532–1546, 2024, doi: 10.32520/stmsi.v13i4.4180.
- [17] W. Nugraha and A. Sasongko, “Hyperparameter Tuning on Classification Algorithm with Grid Search,” *SISTEMASI: Jurnal Sistem Informasi*, vol. 11, no. 2, pp. 391–401, 2022, doi: 10.32520/stmsi.v11i2.1750.
- [18] R. A. Ichwanto, K. Q. Fredlina, and I. G. J. E. Putra, “Klasifikasi Kategori Feedback EDOM Primakara University dengan Algoritma RNN LSTM,” *Journal Scientific of Mandalika (jsm)*, vol. 6, no. 6, pp. 1522–1532, 2025, doi: 10.36312/10.36312/vol6iss6pp1522-1532.